

**SVEUČILIŠTE U SPLITU
EKONOMSKI FAKULTET**

DIPLOMSKI RAD

**TESTIRANJE CAPM MODELA – ANALIZA NA
HRVATSKOM TRŽIŠTU KAPITALA**

Mentor:

Prof.dr.sc. Zdravka Aljinović

Student:

Antonela Sakić

Broj indeksa: 2151138

Split, prosinac 2017.

Sadržaj

1. UVOD	1
1.1. PREDMET ISTRAŽIVANJA.....	1
1.2. HIPOTEZE	2
1.3. CILJ ISTRAŽIVANJA	3
1.4. METODE ISTRAŽIVANJA	3
1.5. DOPRINOS ISTRAŽIVANJA	5
1.6. STRUKTURA RADA	5
2. MARKOWITZEV MODEL	6
2.1. TEORIJSKA ODREĐENJA MARKOWITZEVOG MODELA	7
2.2. PRINOS PORTFELJA I OČEKIVANA VRIJEDNOST PRINOSA	8
2.3. VARIJANCA PRINOSA	10
2.4. EFIKASNA GRANICA	12
2.5. FUNKCIJA KORISNOSTI.....	15
2.6. ZNAČAJ MARKOWITZEVOG MODELA	17
3. CAPM MODEL	20
3.1. TEMELJNE POSTAVKE CAPM MODELA	20
3.2. BETA INDEKS	24
3.3. VAŽNOST MODELA	26
3.4. ISTRAŽIVANJA O CAPM MODELU	27
4. TESTIRANJE CAPM MODELA NA HRVATSKOM TRŽIŠTU KAPITALA.....	30
4.1. HRVATSKO TRŽIŠTE KAPITALA	30
4.2. IZBOR DIONICA UKLJUČENIH U ISTRAŽIVANJE	33
4.3. EFIKASNOST CROBEX-A.....	35
4.4. REGRESIJSKA ANALIZA	41
5. ZAKLJUČAK	45
SAŽETAK.....	47
ABSTRACT	48
POPIS SLIKA I TABLICA.....	49

LITERATURA.....	50
PRILOZI.....	52
PRILOG 1. PREGLED ZAKLJUČNIH CIJENA PO TJEDNIMA ZA ODABRANE DIONICE.....	52
PRILOG 2. PRIKAZ TJEDNOG PRINOSA DIONICA	54
PRILOG 3. MATRICA A	57
PRILOG 4. MJESEČNE CIJENE ZATVARANJA DIONICA	60
PRILOG 5. PRINOSI DIONICA	62

1. UVOD

1.1. Predmet istraživanja

Predmet ovog istraživanja je prikaz Capital Asset Pricing Model-a, povijesti njegova razvoja, temeljnih postavki i važnosti njegove primjene u suvremenoj ekonomiji. Također, vrlo je važno prikazati i njegovu primjenjivost, odnosno provesti istraživanje o primjenjivosti navedenog modela unutar hrvatskog tržišta kapitala. Naime, moderna teorija portfelja za sve racionalne investitore nudi mogućnost optimiziranja portfelja u cilju maksimalizacije svojih prihoda, a da se pritom suočavaju s najmanjim mogućim rizikom. Teorija ujedno pretpostavlja racionalnost svih investitora na tržištu kapitala, odnosno da svi prisutni imaju averziju na rizik i njihove preferenciju uključuju isključivo sigurna ulaganja. Ako se u obzir uzme i standardizirana definicija, racionalni investitori su oni investitori koji će u svakoj situaciji odabrati onaj portfelj koji će mu osigurati veći povrat, međutim, u slučaju da dva portfelja imaju jednak očekivani prinos takav investitor će se uvijek odlučiti za onaj portfelj koji je manje rizičan.

Temeljno pitanje koje se postavlja u financijskom sustavu je kako rizik investicije utječe na njezin očekivani povrat. Model za procjenu kapitalne imovine (CAPM¹) omogućio je prvi koherentni okvir za odgovor za to pitanje. Kroz povijest, vidljivo je kako je čovječanstvo loše shvaćalo rizik još od 1960-ih, bilo u teoretskom ili u smislu empirijskog dokazivanja. Unatoč dugoj povijesti stvarnog rizika i raspodjele rizika na organiziranim financijski tržištima, CAPM model razvijen je u vrijeme kada su teoretske osnove odlučivanja u uvjetima nesigurnosti bile relativno nove te kada osnovne empirijske činjenice o riziku i povratu na tržištu kapitala još uvijek nisu bile poznate. Rigorozne teorije o sklonosti riziku ulagača i odlučivanju u uvjetima nesigurnosti pojavile su se tek 1940-ih i 1950-ih godina. Teorija portfelja, pokazujući kako ulagači mogu stvoriti portfelje pojedinih ulaganja kako bi optimalno zamijenili rizik za prinos, nije razvijena sve do ranih 1950-ih godina od strane Markowitza i Roya. 1940-ih i 1950-ih godina, prije razvoja CAPM modela vladajuća paradigma za procjenu očekivanih prinosa pretpostavljala je da bi povrat koji investitori zahtijevaju (ili „trošak kapitala“) od imovine ovisi prije svega o

¹ Capital Asset Pricing Model

načinu na koji je ta imovina financirana. Postoji „trošak kapitala“ i „trošak duga kapitala“, a njihov ponderirani prosjek, koji se temelji na iznosima financiranja duga i kapitalu, predstavlja trošak kapitala određene imovine. Iz perspektive modernog financiranja, ovaj pristup određivanju troška kapitala bio je vrlo pogrešan. Barem u idealnoj slici svijeta, vrijednost tvrtke ili imovine ne ovisi o tome kako se financira. To ujedno znači i da je trošak kapitala vjerojatno određen troškom kapitala imovine, a ne obrnuto. Štoviše, taj proces zaključivanja troška kapitala iz budućih stopa rasta dividende je vrlo subjektivan. Nema jednostavnog načina za određivanje tržišne prognoze stope rasta budućih novčanih tijekova, a poduzeća s visokim stopama rasta dividende procjenjuju koristeći ovu metodu iz razloga što u tom slučaju imaju visoke troškove temeljnog kapitala.²

1.2. Hipoteze

Definirana glavna hipoteza H1 ovog rada glasi:

CAPM model nije validan na hrvatskom tržištu kapitala.

Uz navedenu, temeljnu, hipotezu postavljaju se i sljedeće pomoćne hipoteze:

H2 – Beta nije u vezi s očekivanim povratom na portfelj.

H3 - CROBEX nije efikasan nadomjestak tržišnog portfelja.

² Perold, A.F., The Capital Asset Pricing Model, Journal of Economic Perspectives vol. 18, No. 3., 2004.

1.3. Cilj istraživanja

Temeljem definiranog problema i predmeta istraživanja postavljaju se ciljevi istraživanja. Cilj izrade diplomskog rada je dati teorijski prikaz CAPM modela i istražiti u kojoj mjeri je CAPM kao model primjeren za primjenu i analizu na hrvatskom tržištu kapitala.

Istraživanje se provodi na hrvatskom tržištu kapitala s ciljem razumijevanja modela i ocjenjivanja njegove validnosti za procjenu kapitalne imovine na hrvatskom tržištu kapitala.

1.4. Metode istraživanja

Za izradu rada bit će korišteni izvori na hrvatskom i engleskom jeziku. Riječ je o knjigama, člancima, te relevantnim internet izvorima. U postupku pisanja ovog rada koriste se općeprihvaćene metode i tehnike znanstvenog istraživanja. Metode koje se koriste prikupljanje, pripremu i obradu podataka koje će biti input istraživačkom procesu su: induktivna metoda, deduktivna metoda, metoda analize, komparativna metoda, metoda dokazivanja, statistička metoda.

Induktivna metoda je sustavna primjena induktivnog načina zaključivanja kojim se na temelju analize pojedinačnih činjenica dolazi do zaključka o općem sudu, od zapažanja konkretnih pojedinačnih slučajeva dolazi do općih zaključaka. Pouzdanost induktivnog zaključka izravno ovisi o: broju istraženih činjenica i slučajeva, reprezentativnosti analiziranih činjenica za određenu pojavu i stupnju pouzdanosti značenja činjenica. Analiza induktivne metode mora uključiti fundamentalni element svakog induktivnog zaključivanja, a to je relacija posebnog - općeg. **Deduktivna metoda** je sustavna primjena deduktivnog načina zaključivanja u kojemu se iz općih sudova izvode posebni i pojedinačni zaključci. Dedukcija uvijek pretpostavlja poznavanje općih znanja na temelju kojih se spoznaje ono posebno ili pojedinačno. Najvažniji elementi deduktivne metode jesu postupci metoda analize, sinteze, apstrakcije, generalizacije i specijalizacije. Deduktivna

metoda u znanosti služi za: objašnjenje činjenica i zakona, za predviđanje budućih događaja, za otkrivanje novih činjenica i zakona, za dokazivanje postavljenih teza, za provjeravanje hipoteza i za znanstveno izlaganje. Indukcija i dedukcija imaju zajednički opći predmet: to je spoznaja jedne pojave kao dijalektičkoga jedinstva općeg i posebnog. Indukcijom i dedukcijom saznaje se veza, odnos te jedinstvo posebnog i općeg. **Metoda analize** je postupak znanstvenog istraživanja raščlanjivanjem složenih pojmova, sudova i zaključaka na njihove jednostavnije sastavne dijelove i elemente. Analiza je postupak mišljenja u kretanju od posebnoga k općem ili izvođenje teorema iz aksioma po utvrđenim pravilima. Analiza je proces redukcije nejednakoga na sve veću jednakost. Prema gnoseološkoj funkciji postoje dvije vrste analize: deskriptivna, kada se opisuju elementi neke cjeline i eksplikativna, kada se pokušava objasniti određena cjelina na temelju njezinih dijelova. **Komparativna metoda** je postupak uspoređivanja istih ih srodnih pojava ili utvrđivanja njihove sličnosti u ponašanju i intenzitetu i razlika među njima. Ova metoda omogućuje istraživačima da dođu do raznih uopćavanja, novih zaključaka koji obogaćuju spoznaju. **Metoda dokazivanja** je jedna od najvažnijih znanstvenih metoda u kojoj su inkorporirane skoro sve metode i svi posebni metodički postupci: analiza i sinteza, generalizacije i specijalizacija, indukcija i dedukcija, apstrakcija i konkretizacija. Svrha metode je utvrditi točnost neke spoznaje. **Statistička metoda** može se nazvati i opće znanstvenom metodom; u novije vrijeme postala jedna od najvažnijih znanstvenih metoda; često se koristi u znanstvenoistraživačkom radu u svim znanstvenim područjima. Istraživanja u znanstvenim područjima društvenih i humanističkih znanosti, nezamisliva su bez primjene statističke metode jer kako je slikovito opisano tvrdnjom (Croxtton) da sociolog lišen statističke metode, često slični na slijepca koji u mračnoj prostoriji hoće opipati crnog mačka koji ne postoji.³

Uz navedene, koristit će se i **matematičke i statističke metode** u svrhu izračuna potrebnih pokazatelja kako bi se u konačnici dobilo empirijsko istraživanje. U tu svrhu korišteni su softverski paketi: MS Excel i SPSS statistički softver.

³ Belak, S., Uvod u znanost, Škola za turistički menadžment u Šibeniku, 2005., str. 125-126

1.5. Doprinos istraživanja

Doprinos ovog istraživanja teoretski je prikaz do sad prikupljenog znanja s ovog područja ekonomije. U svojoj biti, rad odgovara na relevantna pitanja o validnosti CAPM-a te u skladu s tim o pouzdanosti rezultata istraživanja koja se dobiju primjenom modela.

1.6. Struktura rada

Prvi dio rada, uvodni je dio u kojem se šire definira sam predmet istraživanja i njegove temeljne pretpostavke, kao i važnost istoga. Također, definiran je i problem istraživanja, te istraživački ciljevi. Kroz definiranu glavnu, te pomoćne hipoteze rada postavljaju se temelji smjera istraživanja te se na osnovu njih koriste različite metode kako bi se na odgovarajući način iste prihvale ili odbile.

Drugi dio rada teoretski je dio koji donosi prikaz povijesnog razvoja teorije upravljanja portfeljem, razvijene od strane H. Markowitza, temeljne teoretske postavke modela koji je razvio, te sve relevantne pojmove koje je potrebno opisati da bi se ista teorija što bolje razumjela, a odnose se na: prinos portfelja i očekivanu vrijednost i varijancu prinosa, efikasnu granicu portfelja i u konačnici značaj Markowitzevog modela za tadašnju i suvremenu ekonomiju.

Treći dio rada, nakon postavljanja temelja na kojima se bazira, donosi potpuni prikaz CAPM modela s posebnim naglaskom na beta indeks, poznatiji kao mjera sustavnog rizika. Također, od velike je važnosti prikazati i značaj CAPM modela za suvremeno financijsko tržište i dosadašnja istraživanja na temu istoga.

Četvrti dio rada empirijski je dio koji se bavi testiranjem CAPM modela na hrvatskom tržištu kapitala. Uvodno će biti dan osvrt na hrvatsko tržište kapitala, te izbor dionica uključenih u rad. Izvršit će se obrada i izbor podataka koji će se koristiti za testiranje te opisati metodologija i rezultati.

Peti dio rada zaključni je dio u kojem se donose ključna razmatranja na temelju napisanog rada i korištene literature.

2. MARKOWITZEV MODEL

Harry Markowitz rođen je 1927. godine u Chicagu. Pohađao je Sveučilište u Chicagu i diplomirao ekonomiju. Područje je smatrao dovoljno zanimljivim da se upustio i u poslije diplomski studij te došao do znanstvene faze. Markowitz se počinje baviti pitanjem burzi te se interesira i istražuje to područje. Jedna od prvih knjiga, kojom je započeo svoje istraživanje, bila je *The Theory of Investment Value* koju je napisao John Burr Williams 1938. godine. Williams navodi kako vrijednost vrijednosnog papira treba biti sadašnja vrijednost njegovih dividendi – što je u tom razdoblju bila samo priča. Markowitz je vrlo brzo uočio problem u toj teoriji: buduće dividende nisu izvjesno poznate, one su slučajne varijable. Upravo to promatranje navelo Markowitza da proširi Williamsovu teoriju: vrijednost određene vrijednosnice trebala bi biti očekivana sadašnja vrijednost njezinih budućih dividendi.⁴

Osnovna Markowitzeva ideja bila je naći ravnotežu između rizika i prihoda, te izabrati portfelj dionica koji donosi najveću moguću dobit uz najmanji mogući rizik. Naravno, preuzimanjem većeg rizika, moguće je očekivati veći profit. Dakle, njegova ideja je bila formiranje matematičkog modela za izbor portfelja koji donosi najveću stopu prihoda, ali na određenom stupnju rizika. Takav portfelj koji za zadanu stopu rizika ima najveću stopu prihoda, odnosno portfelj koji za zadanu stopu prihoda ima minimalan rizik, Markowitz je nazvao efikasnim portfeljem.⁵

⁴ Varian, H., A Portfolio of Nobel Laureates: Markowitz, Miller and Sharpe, Journal of Economic Perspective Vol. 7, No. 1., 1993.

⁵ Aljinović, Z., Marasović, B., Šego, B., Financijsko modeliranje, Zgombić i Partneri, Zagreb 2008., str. 133-134

2.1. Teorijska određenja Markowitzevog modela

Učinci rizika i neizvjesnosti na cijenu vrijednosnica, na racionalno donošenje odluka, kako individualnih investitora tako i institucija koji odabiru i donose odluke o različitim portfeljima te na odgovarajući odabir projekata koji se uključuju u korporativne kapitalne budžete, značajno privlače pažnju profesionalnih ekonomista te istraživača kapitalnih tržišta i poslovnih financija.⁶ Pri tome, osnove moderne teorije portfelja postavio je američki ekonomist Harry Markowitz i to otkrićem da je varijanca očekivane stope prinosa adekvatna mjera rizika koji prati taj prinos. Izvođenjem izraza za varijancu portfelja istovremeno je pokazao kako se uspješno mogu diverzificirati raspoloživa sredstva za investicije, odnosno kako se može kreirati portfelj financijske aktive kojim se nesistematski rizik, kao dio ukupnog rizika, može značajno reducirati. Po Markowitzu, investitor mora razmotriti dva parametra pri donošenju investicijske odluke – očekivani prinos i varijancu, pa u skladu sa tim njegov model nosi naziv dvofaktorski⁷ model.⁸

Kao takav, Markowitzev model od svojih početaka privlači pažnju mnogih istraživača tijekom 20. i početkom 21. stoljeća. Jednostavnost modela i njegovih rezultata glavni je uzrok velike zastupljenosti u velikom broju istraživanja. Razvijen 1952. godine, Markowitzev model čini temelje moderne teorije portfelja, a izbor optimalnog portfelja temelji na optimizaciji odnosa očekivanog prinosa i pripadnog rizika portfelja. Prema tome, cilj modela je pronaći efikasan portfelj, tj. portfelj koji za danu stopu rizika rezultira najvećom stopom prinosa ili portfelj koji za danu stopu prinosa ostvaruje najmanju stopu rizika.⁹

Markowitz je u svojoj teoriji polazio od određenih pretpostavki ponašanja investitora:

1. da razmatraju svaku investicijsku alternativu, kao distribuciju vjerojatnosti očekivanih prinosa tokom nekog perioda;

⁶ Litner, J., The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets, The Review of economics and statistics Vol. 47. No. 1., 1965.

⁷ two-parametar model ili mean-variance analysis

⁸ Čerdić, I., Diverzifikacija kao osnova za kreiranje optimalnog portfelja, Škola biznisa Vol. 1., 2015.

⁹ Škrinjarić, T., Šoštarić, N., Komplementarnost metodologije Markovljevih lanaca i Markowitzeva modela optimizacije portfelja, Ekonomska misao i praksa Vol. XXIII br.1., 2014.

2. da nastoje očekivanu korisnost u određenom periodu što je moguće više povećati i da njihove krivulje korisnosti pokazuju opadajuću granična korisnost bogatstva;
3. da svoje odluke temelje isključivo na očekivanom prinosu i riziku;
4. da smanjuju rizik na osnovu varijabilnosti očekivanih prinosa i
5. da za određeni nivo rizika preferiraju više prinose nižim, tj. da za dati nivo prinosa preferiraju niži rizik.¹⁰

Prije nego je Markowitz mogao izložiti svoje pravilo o „očekivanom prinosu – varijanci prinosa“, prvo je morao pobiti tada široko prihvaćeni princip da investitor odabire portfelj odabirom vrijednosnica koje maksimiziraju diskontiranu očekivanu vrijednost. Markowitz ističe kako ukoliko investitor prati ovo pravilo, njegov ili njezin portfelj će se sastojati samo od jedne vrijednosnice, uglavnom one koja ima najveći diskontirani očekivani prinos što je ujedno i u suprotnosti s fenomenom diverzifikacije. Stoga se pravilo da investitorovo ponašanje ne odgovara konceptu diverzifikacije portfelja mora u potpunosti odbaciti.¹¹

Markowitzeva teorija je proširena s utjecajem internacionalnih tržišta kapitala od strane Herberta Grubela, koji predlaže investitorima da putem međunarodne (internacionalne) diverzifikacije, zahvaljujući niskom stupnju korelacije između prinosa na različitim burzama širom svijeta, svedu rizik svog portfelja na granicu minimuma.¹²

2.2. Prinos portfelja i očekivana vrijednost prinosa

Očekivana vrijednost slučajne varijable njezina je prosječna vrijednost, pa je očekivani povrat dane vrijednosnice u stvari njezina prosječna vrijednost. Očekivani prinos portfelja vrijednosnih papira jednak je ponderiranom prosjeku očekivanih prinosa svojih pojedinačnih elemenata, pri čemu se ponderi određuju na temelju vrijednosti udjela elementa u ukupnoj vrijednosti portfelja.¹³

¹⁰ Čerdić, ibid.

¹¹ Jarrow, R., et al., Portfolio Theory, Handbooks on OR&MS, 1995., str.33

¹² Čerdić, ibid.

¹³ Čerdić, ibid.

Rizik općenito definiramo kao neizvjesnost budućeg ishoda. Najpoznatiji oblik rizika koji se veže za vrijednosnice jest tržišni rizik ili neizvjesnost u promjeni cijena vrijednosnica. U stručnoj terminologiji česti se rabi riječ volatilnost kako bi se izravno opisao rizik promjene cijena vrijednosnica.¹⁴ Tokom posljednjih godina, mnogo je autora otkrilo da se premija u očekivanom riziku mijenja na pomalo predvidljiv način. Međutim, istraživanja na ovu temu razlikuju se u mnogočemu. Prije svega, razlikuju se po premiji rizika. Neke studije usredotočene su na premiju rizika za velike dionice, primjerice Standard&Poor's 500 (S&P500), dok druge analiziraju premiju rizika na obveznice. Neke od njih rizik definiraju putem razlike između očekivanog prinosa obveznica i očekivanog prinosa dionica, dok su druge fokusirane na definiciju u smislu raspodjele očekivanog prinosa na vrstu imovine i trezorskih zapisa. Nekoliko studija koristi i metode predviđanja kao dio informacija za definiranje premije rizika, dok druge koriste isključivo informacije temeljene na prošlim podacima i trenutnim cijenama.¹⁵

Općenito, smatra se da je tržišni rizik najveći rizik koji postoji u investicijskom poslovanju s vrijednosnicama. Najčešći uzroci promjena cijena vrijednosnica jesu nesklad ponude i potražnje na tržištu, objava poslovnih rezultata poduzeća, spajanja i akvizicije poduzeća te promjena kamatnih stopa. Nadalje, prinosi vrijednosnica slučajne su varijable, a raspodjela prinosa poprima oblik Gaussove raspodjele kako se promatraju duži vremenski periodi. Za kratkoročne vremenske periode povijesne raspodjele prikazuju postojanje ekstremno negativnih prinosa prouzročenih događajima kao što su objava vrlo loših poslovnih rezultata, pojava ekonomske krize ili slom tržišta. Raspodjele prinosa također pokazuju ekstremno pozitivne prinose koji obično uslijede nakon velikih negativnih prinosa kada se tržišta naglo oporavljaju od kriza ili slomova te zbog iznenadne objave dobrog poslovnog rezultata. Tržišni rizik ili volatilnost nije u principu moguće precizno definirati kao što moguće točno odrediti prinos neke vrijednosnice. Promatra li se raspodjela prinosa rizik je moguće povezati sa standardnom devijacijom prinosa.¹⁶ Rizik portfelja mjeren standardnom devijacijom prinosa manji je od ponderiranog prosječnog rizika portfelja

¹⁴ Latković, M., Upravljanje rizicima: identifikacija, mjerenje i kontrola, Financijska teorija i praksa Vol. 26, No. 2.

¹⁵ Sharpe, W., Investor Wealth Measures and expected return, ICFA Continuing Education Series Vol. 1, 1990.

¹⁶ Latković, M., ibid.

samih elemenata. Za portfelj koji se sastoji od dviju ili više vrijednosnica očekivani prinos portfelja izračunava se po formuli:

$$E(R_p) = \sum_{i=1}^m E(R_i)X_i \quad (1)$$

Gdje je:

$E(R_p)$ očekivani prinos portfelja,

$E(R_i)$ očekivani prinos i-te vrijednosnice,

X_i udio ukupnog novca uloženog u kupovinu i-te vrijednosnice,

m ukupan broj vrijednosnica u portfelju.¹⁷

2.3. Varijanca prinosa

Markowitz je još 1952. godine povezoao rizik s varijancom vrijednosti portfelja.¹⁸ Varijanca je statistička mjera disperzije prinosa oko očekivane vrijednosti. Veća varijanca, odnosno standardna devijacija kao njezin kvadratni korijen, predstavlja veću disperziju. Metoda čitanja vrijednosti varijance upućuje na činjenicu da veća disperzija očekivanih prinosa pretpostavlja veću nesigurnost budućeg prinosa, ili rizik. Sljedeća jednadžba predstavlja standardno odstupanje portfelja, ako su u pitanju dva vrijednosna papira, ako ih ima više jednadžba se korigira:

¹⁷ Čerdić, ibid.

¹⁸ Engle, R.F., Risk and volatility: econometric models and financial practice, Nobel Lecture, 2003.

$$\sigma_p = \sqrt{\sum_{i=1}^m \sum_{j=1}^m x_i x_j \sigma_{ij}} \quad (2)$$

Gdje je:

m broj vrijednosnica u portfelju

$x_i x_j$ udio sredstava investiranih u vrijednosnicu (i) odnosno vrijednosnicu (j)

$\Sigma\Sigma$ kovarijance za sve moguće kombinacije parova vrijednosnica u portfelju.¹⁹

Potencijalni je nedostatak standardne devijacije kao mjere rizika simetrično tretiranje pozitivnih i negativnih odstupanja od očekivanog prinosa. U stvarnosti, pozitivna iznenađenja čine ulagače zadovoljnima pa bi prikladna mjera rizika trebala biti usredotočena samo na loše ishode. Međutim, ako je distribucija prinosa simetrična (vjerojatnost negativnih iznenađenja približno je jednaka vjerojatnosti pozitivnih iznenađenja iste veličine), tada će standardna devijacija prinosa biti približna mjera rizika kao da je isključivo usredotočena na negativna odstupanja.²⁰

¹⁹ Čerdić, ibid.

²⁰ Laković, A., Optimizacija portfelja dionica na primjeru Zagrebačke burze, Diplomski rad, Rijeka, 2016.

2.4. Efikasna granica

Markowitz je postavio problem minimaliziranja varijance portfelja kao potrebno ograničenje modela. Ovaj način postavljanja problema sadržavao je dva značajna saznanja. Prvo, Markowitz je shvatio da matematika ne može podići niti jedan optimalni portfelj, već je samo u mogućnosti identificirati određeni skup efikasnih portfelja – skup portfelja koji imaju najmanji mogući rizik za svaki mogući očekivani povrat. Drugo, Markowitz je prepoznao da je odgovarajući rizik s kojim se suočava investitor bio portfeljni rizik – odnosno oscilacija cjelokupnog portfelja rizične imovine.²¹

U svom radu, Burton²² navodi kako je: „*došao Markowitz i stvorio svjetlost*“. Naime, kako je već navedeno, u svom radu Markowitz navodi kako svaki portfelj ima očekivani povrat i rizik. Očekivani povrat odnosi se na očekivani prinos od vrijednosnih papira, no rizik je značajno kompliciraniji. Rizik se odnosi na rizike pojedinih komponenti, ali i na njihove korelacije. Sve zajedno, to čini vrlo složenu karakteristiku, i onu s kojom ljudska bića imaju problema u shvaćanju. Procjena rizika/korelacija povrata može se unijeti u računalo koje će iznaći učinkovite portfelje. Na takav način može se izračunati veći broj povrata za određenu razinu rizika te manji rizik za određeni prinos, što ujedno predstavlja **granicu efikasnosti** *a la* Markowitz.

Budući da je svaki portfelj prema Markowitzu okarakteriziran svojim prinosom (očekivanim prinosom) i svojim rizikom (varijancom prinosa) može se prikazati točkom u koordinatnoj ravnini u kojoj apscisa predstavlja rizik, a ordinata stupanj očekivane stope prinosa. Uobičajeno je i da se kao mjera rizika na apscisi nalazi standardna devijacija prinosa, a ne varijanca.²³

Efikasna granica, može se definirati i krivuljom koja predstavlja skup portfelja koji maksimiziraju prinos za zadanu razinu rizika. Zapravo, ako se pretpostavi da se portfelj definira pomoću očekivanog prinosa i standardne devijacije ujedno se može prikazati u koordinatnom sustavu na način da ordinata predstavlja očekivani prinos $E(R)$, a apscisa


²¹ Varian, H., *ibid*.

²² Burton, J., *Revisiting The Capital Asset Pricing Model*, Dow Jones Asset Manager, 1998., str. 22

²³ Tomić-Plazibat, N., Aljinović, Z., Marasović, B., *Matematički modeli u financijskom upravljanju*, Sveučilište u Splitu, Ekonomski fakultet, Split, 2006., str. 16

standardnu devijaciju (σ).²⁴ Skup mogućih portfelja, u Markowitzevoj teoriji, čine svi portfelji koji se mogu sastaviti od određenog broja zadanih rizičnih vrijednosnica. Svaki portfelj karakteriziran je svojim (očekivanim) prinosom i svojim rizikom (varijancom prinosa ili standardnom devijacijom) i može se prikazati točkom u $\sigma_\pi - E(R_\pi)$ koordinatno sustavu. Prikažu li se svi mogući portfelji točkama u $\sigma_\pi - E(R_\pi)$ koordinatnom sustavu, stvoriti će se skup kao na Slici 1.

Slika 1. Skup mogućih portfelja



Izvor: Aljinović, Z., Marasović, B., Šego, B., Financijsko modeliranje, Zgombić i partneri, 2008...


str.135

Lijeva granica skupa mogućih portfelja se naziva skup minimalne varijance. Njega sačinjavaju točke koje za danu stopu prinosa imaju najmanju varijancu. Dio skupa

²⁴ Laković, A., ibid.

minimalne varijance koji prikazuje portfelje koji za zadanu standardnu devijaciju imaju maksimalan prinos naziva se efikasnom granicom.

Slika 2. Skup minimalne varijance (lijevo) i efikasna granica (desno)



Izvor: Aljinović, Z., Marasović, B., Šego, B., Financijsko modeliranje, Zgombić i partneri, 2008.,
str.136

Efikasna granica ujedno može predstavljati i portfelje s najvišom mogućom očekivanom razinom prinosa kada se u obzir uzme standardna devijacija portfelja. Svi portfelji koji se nalaze ispod točke minimalne varijance mogu se odmah odbaciti iz razloga što u gornjem dijelu efikasne granice (Slika 2.) postoje portfelji koji daju veći očekivani prinos za istu razinu rizika. Efikasni portfelji su svi oni koji se nalaze na efikasnoj granici, ali iznad točke minimalne varijance. Za portfelj se može reći da je efikasan ako ne postoji nijedan drugi portfelj koji ima:

- veći povrat uz manju standardnu devijaciju
- veći povrat i istu standardnu devijaciju

- isti povrat uz manju standardnu devijaciju²⁵

Naravno da je za investitora pri izboru optimalnog modela najvažnije postići što je veći prinos. Međutim ako je to jedini kriterij, tada će on uložiti cijeli iznos na vrijednosnicu s najvećim očekivanim prinosom, koja je često vrlo rizična vrijednosnica s vrlo velikim fluktuacijama prinosa. Osnovna je ideja Markowitza upravo bila naći ravnotežu između rizika (varijance prinosa portfelja) i prinosa (očekivane vrijednosti prinosa portfelja).²⁶

2.5. Funkcija korisnosti

Odabir optimalnog portfelja od strane svakog investitora ovisi u prvom redu o funkciji korisnosti, odnosno isto se može opisati kao stupanj zadovoljstva svakog individualnog investitora prilikom ulaganja u bilo koji vrstu imovine. Funkcija korisnosti ujedno će ovisiti o očekivanom prinosu od ulaganja, ali i o vjerojatnosti nastupa nekog događaja, odnosno o riziku.

Funkcija korisnosti po svojoj definiciji, dakle, je funkcija očekivanog prinosa i standardne devijacije te kad se govori o racionalnom investitoru ta funkcija uvijek ima konkavni oblik koji je karakterističan upravo za ljude koji nisu skloni riziku.²⁷

$$E(U) = f(R, \sigma) \quad (3)$$

Grafički izraz funkcije korisnosti su krivulje indiferencije, što znači da investitor teži izboru portfelja s najviše moguće krivulje indiferencije.²⁸


²⁵ Laković, A., ibid.

²⁶ Aljinović, Z., Marasović, B., Šego, B., ibid., str. 136

²⁷ Laković, A., ibid.

²⁸ Vidučić, Lj., Financijski menadžment, RRI plus, V. izdanje, Split, 2006., str.117

Slika 3. Krivulja indiferencije



Izvor: van Horne, J., Financijsko upravljanje i politika, Deveto izdanje, Mate Zagreb, 1997, str. 57

Očekivani prinos se nanosi na vertikalnu os, a standardna devijacija na vodoravnu. Što je veći nagib krivulja indiferencije, to investitor više izbjegava rizik. Što se više kreće lijevo na Slici 3. svaka naredna krivulja predstavlja višu razinu očekivane korisnosti. Važno je napomenuti da točan oblik krivulja indiferencije neće biti isti za različite investitore. Iako će ovakve krivulje za sve investitore koji izbjegavaju rizik biti pozitivno nagnute, mogući su njihovi različiti oblici, što ovisi o preferencijama rizika biti pozitivno nagnute, mogući su njihovi različiti oblici, što ovisi o preferencijama rizika svakog pojedinog investitora. Svaki investitor želi doseći onaj portfelj vrijednosnih papira koji se nalazi na najvišoj krivulji indiferencije.²⁹

²⁹ van Horne, J., Financijsko upravljanje i politika, Deveto izdanje, Mate Zagreb, 1997., str. 57

2.6. Značaj Markowitzevog modela

Kako u svom radu navodi Bagarić³⁰ vrlo se lako zaključuje da Markowitzev doprinos organizacijskoj teoriji proizlazi prvenstveno iz zaključka da se svi portfelji sastoje od rizičnih vrijednosnih papira te se mogu formirati na način da rizik ukupnog promatranog portfelja bude manji od rizika svakog pojedinačnog vrijednosnog papira unutar istog tog portfelja. Sve dok se na tržištu javlja problem u komparaciji uspješnosti poslovanja poduzeća čiji se vrijednosni papiri kombiniraju unutar portfelja, diverzifikacija uvijek može smanjiti rizik. Drugim riječima, ukoliko se radi o negativnoj vezi između poslovnih uspjeha (ukoliko jedna strana posluje pozitivno, druga gotovo uvijek ima negativno poslovanje), u tom slučaju diverzifikacija može u potpunosti eliminirati rizik portfelja. Naravno, u realnom svijetu situacija je drugačija i uvijek se javljaju problemi, budući da se poslovni uspjeh za većinu poduzeća u principu kreće u istome smjeru (gotovo je nemoguće pronaći vrijednosne papire s korelacijom jednakom nuli). Prema tome, ne može se očekivati da će na jednostavan način i u cijelosti eliminirati sav postojeći rizik. Ipak, budući da se poslovni uspjeh različitih poduzeća ne kreće uvijek u istom smjeru, svako ulaganje u diverzificirani portfelj vrijednosnih papira biti će znatno manje riskantno od ulaganja u samo jedan ili eventualno dva individualna vrijednosna papira. Autor, također, u svom radu navodi kako:

„Iako je Markowitzev koncept teorijski jednostavan i održiv u normalnim tržišnim uvjetima, teorija je imala praktičnih nedostataka, a najveći problem je bio veliki broj ulaznih parametara u optimizaciji. Naime, često formiranje optimalnog portfelja zahtjeva utrošak vremena i novca, a obujam i složenost poslova koji su vezani za formiranje portfelja podrazumijeva visoke cijene usluga profesionalnih analitičara. Kao i svaki model i ovaj predstavlja pojednostavljenje stvarnosti koje se ne može uzeti kao realno stanje. Izbor optimalnog portfelja se promatra kao jednokratni proces (statični model), a ne kao kontinuirani proces praćenja promjena i prilagođavanja portfelja tim promjenama. Dodatni nedostatak jest činjenica da se pri izboru optimalnog portfelja ne uzimaju u obzir transakcijski troškovi. Kada se formiraju portfelji na tržištima tranzicijskih zemalja važna

³⁰ Bagarić, I., Testiranje CAPM modela - analiza na hrvatskom tržištu kapitala, Diplomski rad, Split, 2011.

činjenica koju ne poštuje moderna teorija portfelja jest relativno niska i promjenjiva likvidnost vrijednosnica. Pretpostavka o relativnoj stabilnosti koeficijenta korelacije između vrijednosnica i konstantnoj promjenjivosti vrijednosnica nije realna pretpostavka za tranzicijska tržišta.“

I prije Markowitza postojali su teorijski modeli za donošenje investicijskih odluka koji su obraćali pozornost na očekivani povrat pojedine vrijednosnice kao i na njezin rizik. Razlika između prijašnjih modela i Markowitza je u tome što on prvi uključuje učinak diverzifikacije u donošenje odluke o investiranju. Dakle, osim dvije osnovne varijable, povrata (r) i rizika (σ), koje utječu na odluku o formiranju pojedinog portfelja. Markowitz u svom novom modelu uključuje i novu, treću varijablu – međuovisnost kretanja pojedinačnih vrijednosnica koje se nalaze unutar portfelja, tj. njihovu korelaciju (ρ). Uvođenjem ove varijable investitori sada mogu formirati nove portfelje koji im omogućuju veće povrate, uz isti rizik, ili iste povrate uz manji rizik, bez mijenjanja prve dvije varijable (r i σ).

Kako u svom radu navode Jerončić i Aljinović³¹, iako je Harry M. Markowitz za model 1990. godine dobio i Nobelovu nagradu, model nije prošao bez kritika znanstvene i financijske zajednice. Jedna je od glavnih kritika pretpostavka da su prinosi normalno distribuirani. Naime, prinosi su rezultat cijena koje se formiraju tržišnim snagama koje nisu nasumične, nego se zasnivaju na ekonomskim zakonitostima, te očekivanjima i procjenama investitora. Distribucije prinosa najviše odudaraju od normalne distribucije za vrijeme izrazitog gospodarskog uzleta ili gospodarske krize – onda kada je ispravnost pretpostavki najvažnija. Ostale kritike uključuju pretpostavke racionalnosti investitora i njihove nesklonosti riziku, koje u nekim slučajevima nisu točne, te pretpostavku dobre informiranosti svih investitora za koju je poznato da zbog asimetrije informacija i agencijskog problema nije u potpunosti točna. Transakcijski troškovi i utjecaj poreza, kao i nemogućnost savršenog usitnjavanja vrijednosnica, također predstavljaju prepreke ovom modelu. Unatoč ovim kritikama Markowitzeva teorija portfelja predstavlja najznačajniju inovaciju u 20. stoljeću na području upravljanja portfeljima. Ona je omogućila da se dotadašnja financijska i fundamentalna analiza, koje su bile temeljene na

³¹ Jerončić, M., Aljinović, Z., FORMIRANJE OPTIMALNOG PORTFELJA POMOĆU MARKOWITZEVOG MODELA UZ SEKTORSKU PODJELU KOMPANIJA, Ekonomski pregled Vol. 62., 2011.

računovodstvenim metodama, nadopune sa vrlo moćnim statističkim oruđem, koje u kombinaciji nudi još bolje rezultate i uključuje u analizu kvantificiranu varijablu rizika. Iako u ekstremnim tržišnim uvjetima ponešto neprecizna, u normalnim tržišnim uvjetima, na razvijenim i likvidnim tržištima kapitala, pokazala se kao nezamjenjiv alat u modernom upravljanju portfeljima.

Unatoč važnosti ovog modela, kako u prognostičke svrhe tako i u analizi tržišta kapitala, njegova primjena u praksi u Hrvatskoj gotovo je zanemariva i to iz barem dva razloga. prvi leži u činjenici da je zbog velikog broja matematičkih operacija gotovo nemoguće provesti izračun bez upotrebe računala, a drugi što stručnjaci koji se bave problemima financijskog modeliranja nisu dovoljno upoznati s mogućnostima recentnih programskih paketa razvijanih specijalno za potrebe financijskog modeliranja.³²

³² Tomić-Plazibat, N., Aljinović, Z., Marasović, B., ibid., str. 26

3. CAPM MODEL

Tržište kapitala igra značajnu ulogu u ekonomskom razvoju te predstavlja integrirani dio financijskog sustava.³³ Prisutnost CAPM modela će pokazati da ne postoji veza između troška kapitala i budućih stopa rasta novčanih tijekova na tim istim tržištima kapitala. Ukratko, i prije pojave CAPM modela postavljeno je pitanje o odnosu između očekivanog prinosa i rizika, te se odgovor još uvijek čeka.³⁴

3.1. Temeljne postavke CAPM modela

Kod razvoja modela za procjenu vrijednosti imovine, pretpostavlja se da:
su svi investitori neskloni riziku i između različitih portfelja biraju samo na osnovi srednje vrijednosti i varijance
ne postoje porezi ili bilo kakvi transakcijski troškovi
svi investitori imaju jednake stavove o distribuciji vjerojatnosti svih povrata na vrijednosnice
svi investitori mogu na tržištu uzeti ili dati pozajmicu po određenoj nerizičnoj kamatnoj stopi

Glavni rezultati ovih modela su odnosi između očekivanih premija rizika pojedinačne imovine i njihovog „sustavnog rizika“.³⁵

Nastavno, CAPM je model za stanje ravnoteže koji utvrđuje postojanje pozitivne linearne veze između tražene stope povrata na vrijednosnicu/portfelj i pripadajućeg rizika u portfelj kontekstu. Očekivana stopa povrata jednaka je, naime, zbroju stope povrata bez rizika i premiji na rizik koja odražava diverzifikaciju. Model polazi od izabranih temeljnih

³³ Choudhary, K., Choudhary, S., Testing Capital Asset Pricing Model: Empirical Evidences from Indian Equity Market, Eurasian Journal of Business and Economics Vol. 3., No. 6., 2010.

³⁴ Perold, A.F., ibid.

³⁵ Black, F., Jensen, M.C., Scholes, M., The Capital Asset Pricing Model: Some empirical tests, Praeger Publishers Inc., 1972., str. 3-4

postavki i utvrđuje da uz veći neizbježivi, tržišni rizik, investitori očekuju i veći povrat, te da postoji tržišna ravnoteža.³⁶

CAPM je *ceteris paribus* model, odnosno valjan je samo uz poseban set pretpostavki, a to su:

- Pojam investitora predstavlja individualne osobe sklone riziku koji svoja očekivanja maksimiziraju samo u nekom određenom periodu (kontinuiranom). Implicira se da je model jednokratan.
- Svi investitori imaju homogena očekivanja o prinosu kapitala. Implicira se da svi investitori imaju identične mogućnosti, što bi ujedno značilo i da svi imaju istu informaciju u isto vrijeme.
- Prinos kapitala ima normalnu raspodjelu vjerojatnosti.
- Postoji i bez rizični kapital te svi investitori mogu posuditi neograničenu količinu te vrste kapitala.
- Postoji određiva količina kapitala i njegova količina je stalna u danom periodu.
- Sav kapital je savršeno djeljiv, a njegova cijena je određena na savršenom tržištu. Implicira se da npr. ljudski kapital ne postoji (iz razloga što nije djeljiv i ne može biti u vlasništvu u smislu kapitala).
- Na tržištima kapitala ne postoji otpora te je svaka informacija besplatna i simultano dostupna svim investorima.
- Ne postoje tržišne nesavršenosti kao što su porezi, državna regulativa ili restrikcije bilo koje vrste.³⁷

CAPM, za razliku od Markowitzevog modela, utvrđuje da će investitori ulagati u kombinaciju imovine bez rizika i portfelja rizične imovine, što se i događa u stvarnosti. Investitori, dakle, prilagođavaju rizik svog portfelja određivanjem proporcije portfelja koji se odnosi na rizičnu u odnosu na nerizičnu imovinu.³⁸

Tržišni portfelj obuhvaća sve investicije na tržištu. Cjenovna prilagodba koja ovisi o ponudi i potražnji pojedinih investicija, osigurava da se u ravnoteži sve investicije nalaze u

³⁶ Vidučić, Lj, ibid., str. 126

³⁷ Žiravac Mladenović, M., Najdanović, Z., Procjena beta koeficijenta za akcije koje kotiraju na banjalučkoj berzi, International Conference on Social and Technological Development (STED 2012). 2012.

³⁸ Vidučić, Lj., ibid., str. 127

optimalnom rizičnom portfelju. Svaki investitor odabire svoj portfelj kao linearnu kombinaciju između optimalnog rizičnog portfelja i bez rizične investicije, ovisno o sklonosti prema riziku. Isto tako, model dopušta investitorima koji preferiraju veći rizik (pa i prinos) nego što nudi tržišni portfelj, da posude dodatni iznos po bez rizičnoj kamatnoj stopi, ulože u neku kombinaciju vrijednosnih papira iz tržišnog portfelja i ostvare prinos veći od prinosa tržišnog portfelja. Bez rizična investicija je ona čija je vjerojatnost ostvarivanja očekivanog prinosa jednaka 1. Uobičajeno se za bez rizičnu investiciju uzima kratkoročna državna obveznica.

Postavlja se pitanje, kako što jednostavnije odrediti tržišni portfelj. Pretpostavimo da postoji bez rizična imovina i da ima bezrizični prinos r_f . Neka je R_f vektor kojemu su sve komponente r_f . Tada je tržišni portfelj M normirani vektor vektora z koji je rješenje matrične jednadžbe:

$$E(R) - R_f = Sz \quad (4)$$

$$x_i^M = \frac{z_i}{\sum_{i=1}^n z_i} \quad (5)$$

Promatramo sada portfelje koji su kombinacija tržišnog portfelja M i bez rizične imovine, i neka je udio bez rizične imovine a . Tada su očekivani prinos i standardna devijacija tako složenog portfelja π dani relacijama:


$$E(R_\pi) = ar_f + (1 - a)E(R_M) \quad (6)$$

$$\sigma_\pi = \sqrt{a^2\sigma^2 + (1 - a)^2\sigma_M^2 + 2a(1 - a)\text{Cov}(R_f, M)} = (1 - a)\sigma_M \quad (7)$$

Grafički prikaz svih takvih kombinacija za $a \geq 0$ je polupravac koji se naziva linija tržišta kapitala – CML (*capital market line*). CML je tangenta na efikasnu granicu za rizične vrijednosnice. Svaka točka na CML-u je portfelj rizične i bez rizične imovine, osim točke

M koja predstavlja portfelja sačinjen samo od rizične imovine. Može se reći da je CML efikasni skup ukupne imovine – rizične i bez rizične.

Slika 4. Linija tržišta kapitala - CML



Izvor: Izvor: Aljinović, Z., Marasović, B., Šego, B., Financijsko modeliranje (II. izmijenjeno i dopunjeno izdanje), Sveučilište u Splitu, Ekonomski fakultet, 2011., str.155

Vidljivo je da nije problem odrediti tržišni portfelj M kada je poznata bez rizična kamatna stopa r_f . Potrebno je pronaći efikasni portfelj za danu konstantu $c = r_f$. Ono što se traži je tangencijalni portfelj za danu konstantu.

Pokazuje se da kod takvih investicijskih mogućnosti kada postoji bez rizična imovina, očekivani prinos portfelja π računa se prema slijedećoj relaciji, pod nazivom SML – security market line³⁹:

$$E(R_{\pi}) = r_f + \beta_{\pi}[E(R_M) - r_f] \quad (8)$$

Pri čemu je:

$$\beta_{\pi} = \frac{Cov(\pi, M)}{\sigma_M^2} \quad (9)$$

3.2. Beta indeks

CAPM objašnjava kako svako tržište kapitala na svijetu postavlja cijene vrijednosnih papira odnosno vrednuje investicije kroz koncept očekivanog prinosa, a pritom uzimajući u obzir prirodu rizika kojemu su svi vrijednosni papiri na tom tržištu izloženi, što uključuje i pojedine specifične vrijednosnice. CAPM model opisuje i odnos između rizika i očekivanog prinosa te služi kao model za utvrđivanje vrijednosti rizičnih vrijednosnih papira. U osnovi samog modela je formula putem koje se izračunava očekivani prinos vrijednosnog papira ili portfelja, pritom polazeći od stope prinosa nerizičnog vrijednosnog papira na koju se zatim dodaje premija rizika. Točnije, definira se rizik pomoću indeksa **beta**, koji mjeri rizik kojemu je izložen jedan (određeni) vrijednosni papir, uspoređujući ga sa cijelim tržištem kojem pripada.⁴⁰

Beta koeficijent mjeri volatilnost očekivanog rezultata specifičnih ulaganja (bilo da je riječ o materijalnoj ili financijskoj imovini) u odnosu na učinkovitost cjelokupnog tržišta

³⁹ Aljinović, Z., Marasović, B., Šego, ibid., 154-155

⁴⁰ Žiravac Mladenović, M., Najdanović, Z., ibid.

kapitala. Stoga, naziva se još i mjerom sustavnog rizika financijske imovine, investicijskog projekta, poslovnog subjekta ili bilo koje druge vrste imovine.⁴¹

Beta se može izračunati iz odnosa kovarijance povrata vrijednosnice i povrata tržišnog portfelja, s varijancom tržišnog indeksa:

$$\beta_j = \frac{Cov(R_j, R_m)}{SD^2(R_m)} \quad (10)$$

Gdje je:

$$Cov(R_j, R_m) = \sum P_i(R_j - \bar{R}_j)(R_m - \bar{R}_m) \quad (11)$$

Usvajanje bete za odgovarajuću mjeru rizika u korporacijskim financijama znači da se procjena rizika u odlukama financijskog menadžmenta treba provoditi u kontekstu povezanosti konkretne financijske odluke i tržišta.⁴²

Interpretacija vrijednosti beta koeficijenta određenog ulaganja polazi od veze očekivanih prinosa na određeni vrijednosni papir i stope prinosa koja se može ostvariti na tržištu na ulaganja istog rizika. U situaciji kad određeno ulaganje donosi prinose u visini prosječnog tržišnog, odnosno pri postojanju direktne proporcionalnosti prinosa pojedinačnog vrijednosnog papira sa prinosom tržišnog portfelja kojem pripada, onda vrijednost beta koeficijenta iznosi jedan ($\beta = 1$). To ujedno znači i da će, kod ulaganja odnosno vrijednosnog papira koji ima $\beta = 1$, stopa prinosa dugoročno fluktuirati u istom pravcu i istom jačinom kao i stopa prinosa cijelog portfelja. Situacija u kojoj je $\beta > 1$ ukazuje da je prinos određenog vrijednosnog papira veći od prinosa tržišnog portfelja, ali znači i da je taj vrijednosni papir značajno opterećen većim sustavnim rizikom od tržišnog. Za $\beta < 1$ vrijednosni papir je opterećen manjim sustavnim rizikom nego tržišni portfelj, ali i istovremeno obećava i manji prinos od prinosa tržišnog portfelja. Negativne vrijednosti β

⁴¹ Karačić, D., Bestvina Bukvić, I., Research of investment risk using beta coefficient, Interdisciplinary management Vol. X., 2014.

⁴² Vidučić, Lj., ibid., str. 136

koeficijenta pokazuju da se određeni prinos kreće u obrnutom smjeru od kretanja prinosa tržišnog portfelja.⁴³

3.3. Važnost modela

CAPM model postavljen od strane Williama Sharpea (1964.) i Johna Litnera (1965.) obilježava rođenje teorije o vrijednosti imovine (što je ujedno i rezultiralo i Nobelovom nagradom za Sharpea 1990. godine). Četiri desetljeća kasnije, CAPM je i dalje široko korišten u aplikacijama, posebice onima za procjenu troška kapitala za tvrtke i procjenu uspješnosti upravljanja portfeljima. Predstavlja i središnji dio investicijskih tečajeva, i zaista predstavlja često i jedini model koji se podučava na takvim tečajevima. Privlačnost CAPM modela je u tome da nudi snažna i intuitivno predvidljiva predviđanja o tome kako mjeriti rizik i odnos između očekivanog povrata i rizika.⁴⁴ Još od postavljanja CAPM modela i kasnije razvijenih multi-indeks modela, uvijek je pretpostavljana linearna veza između prinosa i rizika. Pri tome je vrijedilo pravilo da veća izloženost riziku donosi i veći prinos. U svojoj osnovi, takav odnos je nepobijen do današnjih dana, no najvjerojatniji razlog tome treba tražiti u pretpostavkama modela koji idealiziraju financijsku realnost.⁴⁵

Verzija CAPM-a koju su razvili Sharpe (1964) i Lintner (1965) nikad zapravo nije bila empirijski uspjeh. Raniji empirijski radovi, u drugim verzijama modela koje mogu podnijeti veći tržišni promet od samo prosječnog povrata i beta indeksa, ima neki tržišni uspjeh. Međutim, u kasnim sedamdesetima istraživanja počinju otkrivati varijable poput veličine, različitih omjera cijena ali i dodatnih objašnjenja prosječnih prinosa korištenjem bete. Problemi s kojima se model susreće dovoljno su veliki da ponište većinu primjena CAPM-a. primjerice, financijski udžbenici često preporučuju korištenje Sharpe-Lintner

⁴³ Žiravac Mladenović, M., Najdanović, Z., ibid.

⁴⁴ Fama, E.F., French, K.R., The Capital Asset Pricing Model: Theory and Evidence, The Journal of Economic Perspectives, Vol. 18, No. 3, 2004.

⁴⁵ Učkar, D., Nikolić, J., SML model i hrvatsko tržište kapitala, Ekonomska istraživanja Vol. 21, No. 1., 2008.

CAPM odnosa između rizika i prinosa kako bi se procijenio trošak kapitala. Savjetuje se da se procjeni vrijednost bete za navedeno tržište vrijednosnih papira te da se kombinira s nerizičnom kamatnom stopom i prosječnom premijom tržišnog rizika kako bi se optimalno procijenio trošak kapitala.⁴⁶

3.4. Istraživanja o CAPM modelu

Model vrednovanja sredstava na tržištu kapitala je široko korišteni model u praksi razvijenih tržišta usprkos ograničenjima koja ga karakteriziraju. Navedeni model vrednovanja imovine na tržištu kapitala (CAPM) ustanovljava vezu između zahtijevane stope prinosa vrijednosnog papira i njegovog rizika.⁴⁷ Početna istraživanja CAPM modela uglavnom su bila zasnovana na individualnim povratima na vrijednosnice i isticali su odnos rizika i povrata. Dobiveni empirijski rezultati nikako nisu bili ohrabrujući. Također, drugi istraživači nailazili su na statističke probleme pri korištenju povrata pojedinačnih vrijednosnica u testiranju valjanosti CAPM-a. Većina studija naknadno je nadvladala ovaj problem na način da su u istraživanje uvedenu prinosi na portfelj.

Naknadno provedene studije, međutim, daju vrlo slabe empirijske dokaze o tim odnosima. Mješoviti empirijski nalazi o odnosu prinos – beta potaknuli su i donošenje brojnih zaključaka:

- CAPM ne može biti prihvaćen sve dok je portfelj koji se koristi neučinkovit. Čak i vrlo mala odstupanja od učinkovitosti mogu proizvesti neznatan odnos između rizika i očekivanog prinosa
- Istaknuta je pristranost u doživljavanju podataka koji se koriste za ispitivanje valjanosti specifikacija CAPM modela
- Beta je proglašena nepouzdanom⁴⁸

⁴⁶ Fama, E.F., Fench, K.R., ibid.

⁴⁷ Janković, D., PRIMJENA CAPM U VREDNOVANJU IMOVINE NA CRNOGORSKOM TRŽIŠTU KAPITALA, Montenegrin Journal of Economics, Vol. 10., 2009.

⁴⁸ Choudhary, K., Choudhary, S., ibid.

CAPM se prema istraživanjima smatra logičnim i racionalnim modelom. Međutim, postoje neka ograničenja koja zahtijevaju respektiranje pri primjeni u odlukama financijskih menadžera, a u teoriji vode prijedlozima za unaprjeđenje samog modela. Jedna od najvažnijih zamjerki je da, premda se radi o vrlo preciznom modelu, njegove parametre je vrlo teško procijeniti, što umanjuje njegovu objektivnost, a time i primjenjivost. Empirijska istraživanja ukazuju da povijesne bete nisu dobra procjena rizika pojedinačne vrijednosnice, ali da su dobre procjene varijabilnosti za portfelje koji se sastoje od 10 ili više slučajno izabranih vrijednosnica. Isto tako, utvrđeno je da model ne vrijedi kada se u portfelj uključe i obveznice. Najčešće zamjerke modelu mogu se sistematizirati na sljedeći način:

- Nesavršenosti u realnom svijetu umanjuju njegovu primjenjivost – treba ga učiniti operativnijim
- Radi se uglavnom o modelu u kojem su empirijski testovi u skladu s hipotezom o postojanju funkcijske veze između rizika i povrata za duga razdoblja, te za kraća razdoblja kada se koriste godišnji, a ne mjesečni podaci
- Postoje razlike korištenih varijabli i bete ovisno o vremenskom razdoblju analize ili metodi procjene (npr. bete za pojedine dionice pokazuju različite vrijednosti ovisno o tome koji nadomjestak tržišnog indeksa se koristi)

Radi eliminiranja ograničenja po svojoj prirodi, model je proširivan uvođenjem:

- Poreza – uključivanje poreza ima za posljedicu da investitori očekuju veću stopu povrata na dionice s višim dividendama (ako su dividende oporezive) nego na one s nižim dividendama (i višim kapitalnim dobitkom)
- Kovarijance (praćenja) povrata na vrijednosnice nepredviđenih promjena stope inflacije – uvođenje kovarijance ima za posljedicu da je uz veću kovarijancu niža tražena stopa povrata
- Likvidnosti i veličine – za vrijednosnice tvrtki s manjom tržišnom kapitalizacijom model pretpostavlja veću traženu stopu povrata što se dokazuje i u praksi
- Efekta omjera cijene/zarade (P/E) – očekivana stopa povrata na dionice s nižim omjerom P/E bit će viša od stope na dionice s višim P/E omjerom

Pri tom su zadnje dvije varijable najznačajnije (nakon bete) u objašnjenju očekivane stope povrata.⁴⁹

⁴⁹ Vidučić, Lj., ibid. 128-129

4. TESTIRANJE CAPM MODELA NA HRVATSKOM TRŽIŠTU KAPITALA

4.1. Hrvatsko tržište kapitala

Zagrebačka burza utemeljena je 1907. u sklopu Trgovačkog doma (današnje Gospodarske komore) kao Sekcija za robu i vrednote, i kao takva funkcionirala je do 1911. Nakon 1. svjetskog rata, Zagrebačka burza ponovno je otvorena 1919. pod nazivom Zagrebačka burza za robu i vrednote, uživajući povjerenje klijenata iz inozemstva, posebice Beča i Praga, te su se brojne novčane transakcije odvijale upravo preko nje, čineći osnovu snažnog zagrebačkog bankarstva i novčarstva onoga vremena. Godine 1945., dolaskom socijalističkog režima na vlast, Zagrebačka burza ponovno je zatvorena. Obnova burze u Hrvatskoj uslijedila je tek 1991. godine, kada je 25 banaka i 2 osiguravajuća društva utemeljilo Zagrebačku burzu kao centralno mjesto trgovine vrijednosnim papirima u Republici Hrvatskoj. Koliko se brzo razvijalo dioničarstvo i burzovna trgovina u nas najbolje je vidljivo iz podatka da je u prvih pet godina nakon uvođenja elektroničkog sustava trgovanja, dakle od 1995. pa do 2000. godine, vrijednost tržišta Zagrebačke burze narasla gotovo 10 puta. Danas je na Zagrebačku burzu uvršteno više od 150 društava, a Burza upravlja dvama tržištima: Uređenim tržištem i Multilateralnom trgovinskom platformom.

Od 2010. Zagrebačka burza uvela je neke značajne novitete na domaće tržište kapitala: pokrenuta je specijalistička trgovina, započelo je trgovanje strukturiranim proizvodima, Burza je počela upravljati Multilateralnom trgovinskom platformom, uvedeno je osam novih indeksa, a započelo je i izdavanje LEI oznaka. Zagrebačka burza također je utemeljila i nagrade za najbolje odnose s ulagateljima (u suradnji s Poslovnim dnevnikom) te godišnje Nagrade Zagrebačke burze. Uz potporu Europske banke za obnovu i razvoj, godine 2010. osnovana je i Akademija Zagrebačke burze, kroz koju je do sada prošlo više od 6,000 polaznika. Zajedno s Bugarskom i Makedonskom burzom, Zagrebačka burza 2014. godine osnovala je društvo SEE Link, s ciljem stvaranja regionalne infrastrukture za trgovanje dionicama uvrštenima na ta tri tržišta. SEE Link platforma postala je operativna u prvom kvartalu 2016. godine. Na samome kraju 2015. godine, Zagrebačka burza

uspješno je završila proces preuzimanja Ljubljanske burze od CEE Stock Exchange Group. Obzirom da obje burze dijele razvojni put i okvir u kojem posluju, a uzimajući u obzir sličnosti slovenskog i hrvatskog tržišta kapitala gledajući stupanj razvoja, strukturu i potencijal, očekuju se brojni pozitivni učinci i sinergije ove akvizicije za oba tržišta. Osnovan u rujnu 2016., Funderbeam South-East Europe društvo je sa sjedištem u Zagrebu, u kojem Zagrebačka burza ima 20%-tni udio. Osnovano je u partnerstvu s Funderbeamom iz Estonije, a poduprto od strane Europske banke za obnovu i razvoj kroz njihov Shareholders Special Fund. Funderbeam je crowdfunding platforma za startup kompanije na kojoj ulagatelji odmah nakon inicijalne faze ulaganja mogu trgovati svojim udjelima, a zahvaljujući inovativnom sustavu temeljenom na bitcoin tehnologiji.

Već 25 godina Zagrebačka burza predvodi trendove u razvoju regionalnog tržišta kapitala, omogućujući transparentnu, sigurnu, učinkovitu i održivu trgovinu vrijednosnicama te održavajući najveću razinu kvalitete usluga tržišta kapitala kako bi se zadovoljile potrebe dioničara, ulagatelja, izdavatelja, članova i svih zainteresiranih strana.⁵⁰

Kako je već i navedeno, Hrvatsko tržište kapitala je jedan duži period nakon svog osnivanja bilo slabo razvijeno. Možemo reći da je de facto postojalo samo na papiru i u zakonima, a da nije ispunjavalo svoje osnovne funkcije:

1. Pribavljanje kapitala potrebnog za financiranje poslovanja i ekspanzije poduzeća
2. Tržišno vrjednovanje poduzeća
3. Mobiliziranje decentralizirane štednje u privredne svrhe
4. Povećanje stupnja mobilnosti investicija (omogućuje investitorima održavanje potrebne razine likvidnosti kupnjom i prodajom vrijednosnih papira).

Drugim riječima, nisu stvoreni uvjeti za povezivanje ponude i potražnje vrijednosnih papira (funkcija burze prema Zakonu o tržištu vrijednosnih papira). Razlozi su tome bili i na strani ponude (nedovoljan broj dionica zanimljivih kupcima) i na strani potražnje (pomanjkanje investitora).

Osnovni uzrok neatraktivnosti dionica u kontekstu analize portfelja je bila netransparentnost poslovanja poduzeća, mali broj dionica i njihova nelikvidnost. Nelikvidnost se očituje u broju dana netrgovanja koji je za većinu dionica bio jako velik.

⁵⁰ Zagrebačka burza, www.zse.hr

Uključivanjem takvih dionica nije se mogla postići zadovoljavajuća diverzifikacija rizika portfelja te su se takve dionice u pravilu kupovale u spekulativne svrhe. Prijelomna točka je bilo donošenje Zakona o tržištu vrijednosnih papira koji je stupio na snagu 25. srpnja 2002. godine. Stroge odredbe toga zakona su "prisilile" velik broj poduzeća ustrojenih kao dionička društva da "izađu" (*going-public*) na burzu, tj. da ispune uvjete za kotiranje u nekoj od kotacija burze. Sama po sebi ova odredba, tj. sama činjenica da poduzeće kotira na burzi ne bi mnogo značila za razvoj tržišta kapitala. Međutim, kotiranje na burzi obvezuje dionička društva na ispunjavanje određenih uvjeta, kao što su periodično objavljivanje financijskih izvještaja kao osnove razumijevanja sigurnosti i uspješnosti poslovanja poduzeća, što bi trebali biti glavni čimbenici odluke investitora o kupnji ili prodaji dionica. Prema tome, povećanje ponude vrijednosnih papira kao i poboljšana transparentnost njihovih izdavatelja u kombinaciji s liberalizacijom (izmjena Zakona o deviznom poslovanju) i ulaskom jakih institucionalnih investitora (banke, investicijski fondovi, mirovinski fondovi, osiguravajuća društva...), tj. porastom potražnje za vrijednosnim papirima dalo je snažan zamah razvoju hrvatskog tržišta kapitala u vidu značajnog porasta prometa, tržišne kapitalizacije, broja transakcija, burzovnih indeksa i cijene dionica na burzama.⁵¹

Tržište kapitala Republike Hrvatske sadrži nekoliko ključnih institucija, a to su:

- Hrvatska agencija za nadzor financijskih usluga (HANFA)
- Zagrebačka burza (ZSE)
- Brokerske agencije i banke koje su ovlaštene za posredovanje u trgovini vrijednosnim papirima
- Središnje klirinško depozitarno društvo (SKDD)
- Tržište novca i kratkoročnih vrijednosnica - Zagreb⁵²

⁵¹ Jakšić, S., Primjena Markowitzeve teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, godina 5, 2007.

⁵² Šupe, N., Prinosi i rizici dionica na tržištu kapitala Republike Hrvatske, Sveučilište u Splitu, Ekonomski fakultet, Split, 2016.

4.2. Izbor dionica uključenih u istraživanje

Dionice odabrane za provođenje empirijskog istraživanja prikazane su, zajedno s tvrtkama izdavateljima u Tablici 2.. Pritom, važno je napomenuti da su u analizu uključeni prikazi tjednih zatvaranja cijena dionica (Prilog 1).

Prilikom odabira dionica koje će se uzimati u obzir prilikom istraživanja postavljeno je nekoliko kriterija. Radi potrebe diverzifikacije portfelja, odnosno da bi se što realnije prikazali izračuni za diverzificirani portfelj, dionice su birane iz različitih sektora. Također, u obzir je uzimana i likvidnost dionice odnosno činjenica da se dionica u svakom trenutku na tržištu može kupiti ili prodati i posljednji je kriterij da je svaka od dionica koje ulaze u istraživanje dijelom CROBEXA

Tablica 1. Uzorak dionica koje su izabrane za istraživanje⁵³

	Simbol	Izdavatelj
1.	<u>ADRS-P-A</u>	Adris grupa d.d.
2.	<u>ATGR-R-A</u>	Atlantic Grupa d.d.
3.	<u>ATPL-R-A</u>	Atlantska Plovidba d.d.
4.	<u>HT-R-A</u>	HT d.d.
5.	<u>KRAS-R-A</u>	Kraš d.d.
6.	<u>LKPC-R-A</u>	Luka Ploče d.d.
7.	<u>PODR-R-A</u>	Podravka d.d.
8.	<u>PTKM-R-A</u>	Petrokemija d.d.
9.	<u>ULPL-R-A</u>	Uljanik plovidba d.d.
10.	<u>ZABA-R-A</u>	Zagrebačka banka d.d.

⁵³ Izvor: www.zse.hr

Prva u portfelju, dionica Adris grupe d.d. redovna je dionica uvrštena na Zagrebačku burzu. Ukupan broj dionica je 9.615.900 a njezina nominalna vrijednost je 10 kn. Njezina najveća zabilježena cijena na tržištu iskazana s 620 kn po dionici, a najniža zabilježena cijena bila je 478 kn po dionici. Dionica Atlantic Grupe d.d. druga je po redu dionica odabrana u portfelju, također je redovna dionica uvrštena na službeno tržište po nominalnoj vrijednosti od 40 kn po dionici. Ukupna broj izdanih dionica je 3.334.300 dionica, s najvećom zabilježenom vrijednosti 1.010 kn, odnosno najnižom cijenom od 736 kn. Dionice Atlantske plovidbe na tržištu se javljaju u ukupnom broju od 1.395.520 dionica nominalne vrijednosti 300 kn po dionici,. Najviša zabilježena cijena bila je 549 kn, dok se najniža kretala na 253,15 kn. Broj dionica HT d.d. uvršten na službeno tržište iznosi 81.888.535 dionica, uz napomenu da je najviša zabilježena cijena u posljednja 52 tjedna bila 191,05 kn, a najniža 159 kn. Dionice tvrtke Kraš d.d. na službenom tržištu kao redovne dionice pojavljuju se u broju 1.373.621 dionica, nominalne vrijednosti 400 kn po dionici te najvišom zabilježenom vrijednosti od 578 kn, a najnižom od 435 kn. Luka Ploče d.d. u trgovanju sudjeluje s 422.967 dionica nominalne vrijednosti 400 kn po dionici. Najviša zabilježena vrijednost dionice bila je 598,58 kn, dok je najniža cijena iznosila 481,01 kn. Podravka d.d. na službenom tržištu sudjeluje s 7.120.003 dionice nominalne vrijednosti 220 kn po dionici. Zabilježena najviša vrijednost bila je 435 kn, dok je najniža 283 kn. Dionice tvrtke Petrokemija d.d. redovne su dionice koje na službenom tržištu sudjeluju u broju od 4.290.393 dionice, nominalne vrijednosti 10 kn po dionici. Najviša cijena navedene dionice zabilježena je u iznosu od 23,45 kn, dok je najniža zabilježena cijena bila 7,10 kn. Uljanik plovidba d.d. na službenom tržištu, sudjeluje s 580.000 redovnih dionica od kojih svaka ima nominalnu vrijednost od 400 kn. Njezina najviša zabilježena vrijednost na tržištu iznosila je 214,99 kn, dok je najniža bila 114 kn. Posljednja dionica u izabranom portfelju dionica je Zagrebačke banke d.d. koje se javljaju u ukupnom broju od 320.241.955 dionica nominalne vrijednosti 20 kn. Najviša zabilježena vrijednost iznosila je 67 kn, dok je najniža zabilježena vrijednost dionice iznosila 44,27 kn.

4.3. Efikasnost CROBEX-a

Za potrebe istraživanja korišteni su podaci o zaključnim cijenama po tjednima za odabranih 10 dionica CROBEX-a od posljednjeg tjedna 2015. godine, zaključno s 27. ožujka 2017. prikazani u Prilogu 1.

Na osnovu cijena iz promatranog razdoblja računaju se i tjedni prinosi dionica (Prilog 2). Za tjedan t i dionicu X prinos se definira relacijom

$$R_x(t) = \ln \left(\frac{P_x(t)}{P_x(t-1)} \right) \quad (12)$$

Gdje je:

$P_x(t)$ cijena dionice X u razdoblju t

a $P_x(t-1)$ cijena dionice X u razdoblju $t-1$

Slijedeći korak je izračun matrice A (Prilog 3), a ona se dobiva na način da se element matrice A na poziciji (i,j) računa tako da se od j -tog prinosa dionice i oduzme očekivani prinos te dionice, tj u konkretnom primjeru od prinosa dionice za određeni tjedan oduzima se očekivani tjedni prinos te dionice, što je prikazano formulom:

$$R_{ij} = R_{ij} - E(R_i) \quad (13)$$

Nakon izračuna matrice A , slijedi izračun matrice varijanci i kovarijanci (matrice S), koja je izuzetno važna za nastavak kvantitativne analize te za izračun efikasne granice i za izračun bete. Matematička formula za izračun matrice S je:

$$S = \frac{A^T A}{n} \quad (14)$$

Gdje je:

A^T transponirana matrica

N je broj prinosa

Uvrštavanjem podataka u navedenu formulu u Microsoft Excelu, dobili se podaci prikazani u Tablici 4:

Tablica 2. Matrica varijanci i kovarijanci ⁵⁴

Matrica varijanci i kovarijanci										
	ADRS2	ATGR	ATPL	HT	KRAS	LKPC	PODR	PTKM	ULPL	ZABA
ADRS2	0,00052	0,00014	0,00022	0,00017	0,00002	0,00015	0,00025	0,00012	0,00018	0,00013
ATGR	0,00014	0,00033	0,00006	0,00017	0,00007	0,00008	0,00011	0,00011	0,00011	0,00009
ATPL	0,00022	0,00006	0,00649	0,00003	0,00031	0,00033	0,00024	0,00232	0,00251	0,00015
HT	0,00017	0,00017	0,00003	0,00034	0,00006	0,00010	0,00008	0,00015	0,00002	0,00010
KRAS	0,00002	0,00007	0,00031	0,00006	0,00040	0,00002	0,00002	0,00025	0,00012	0,00013
LKPC	0,00015	0,00008	0,00033	0,00010	0,00002	0,00062	0,00015	0,00065	0,00028	0,00027
PODR	0,00025	0,00011	0,00024	0,00008	0,00002	0,00015	0,00062	0,00041	0,00021	0,00013
PTKM	0,00012	0,00011	0,00232	0,00015	0,00025	0,00065	0,00041	0,00543	0,00123	0,00051
ULPL	0,00018	0,00011	0,00251	0,00002	0,00012	0,00028	0,00021	0,00123	0,00357	0,00000
ZABA	0,00013	0,00009	0,00015	0,00010	0,00013	0,00027	0,00013	0,00051	0,00000	0,00104

⁵⁴ Izračun autora

Na temelju prikazanih podataka u Tablici 2, izračunati su prosječan tjedni prinos, te standardna devijacija za odabrane dionice, prikazane u Tablici 3:

Tablica 3. Prosječan tjedni prinos i standardna devijacija odabranih dionica⁵⁵

Prosječan tjedni prinos i rizičnost mjerena standardnom devijacijom za 10 odabranih dionica						
	CROBEX	ADRS2	ATGR	ATPL	HT	
E (R)	0,34%	0,42%	0,08%	1,79%	0,28%	
σ^2	0,00019542	0,0005179	0,0003333	0,00648691	0,0003447	
σ	1,40%	2,28%	1,83%	8,05%	1,86%	

	KRAS	LKPC	PODR	PTKM	ULPL	ZABA
E (R)	0,08%	-0,33%	0,17%	0,22%	0,51%	0,83%
σ^2	0,000395	0,000622	0,000618	0,005434	0,003569	0,001042
σ	1,99%	2,49%	2,49%	7,37%	5,97%	3,23%

Nakon izračuna matrice varijanci i kovarijanci izračunava se efikasna granica koja se u Microsoft Excelu dobiva pomoću opcije SOLVER.

⁵⁵ Izračun autora

U Solveru se rješava problem kojeg matematički možemo iskazati:

$$\text{Max } E(R_n) \quad (15)$$

Uz ograničenja:

$$\sigma_\pi \leq C_1 \quad (16)$$

$$\sum_{i=1}^n \pi_i \quad (17)$$

$$\pi_i \geq 0 \quad (18)$$

Slijedećim korakom izračunato je 10 portfelja, koji se ujedno nalaze i na efikasnoj granici. Razina rizika kretala se od 1,30% do 2,20%, dok su se prinosi portfelja kretali od 0,32% do 0,79%. slijedeća tablica prikazuje udjele pojedinih dionica te prinose i rizike (standardne devijacije) portfelja, koji za određenu razinu rizika imaju maksimalan očekivani prinos.


Tablica 4. Prikaz prinosa i standardne devijacije dionica⁵⁶

E(R)	σ	ADRS2	ATGR	ATPL	HT	KRAS	LKPC	PODR	PTKM	ULPL	ZABA
0,65%	1,83%	0,23	0,00	0,11	0,34	0,01	0,00	0,00	0,00	0,00	0,32
0,48%	1,50%	0,19	0,04	0,06	0,31	0,14	0,00	0,05	0,00	0,00	0,21

⁵⁶ Izračun autora

0,59%	1,70%	0,22	0,00	0,09	0,34	0,06	0,00	0,01	0,00	0,00	0,27
0,53%	1,60%	0,21	0,00	0,08	0,33	0,11	0,00	0,03	0,00	0,00	0,24
0,41%	1,40%	0,16	0,07	0,05	0,29	0,18	0,00	0,07	0,00	0,01	0,17
0,32%	1,30%	0,13	0,14	0,02	0,25	0,23	0,00	0,09	0,00	0,02	0,12
0,63%	1,80%	0,23	0,00	0,10	0,33	0,02	0,00	0,00	0,00	0,00	0,31
0,68%	1,90%	0,22	0,00	0,12	0,32	0,00	0,00	0,00	0,00	0,00	0,34
0,72%	2,00%	0,23	0,00	0,14	0,27	0,00	0,00	0,00	0,00	0,00	0,37
0,79%	2,20%	0,22	0,00	0,16	0,2	0,00	0,00	0,00	0,00	0,00	0,42

Različitih rješenja predstavljaju odgovarajuće udjele vrijednosnica u portfelju koji je efikasan. Na taj način se dolazi do čitavog niza efikasnih portfelja koje tvore efikasnu granicu. Ponuđena rješenja su efikasna, ali efikasnih ima mnogo kao što to prikazuje i Grafikon 1, te izbor portfelja ovisi isključivo o investitorovoj sklonosti prema riziku, odnosno osobnoj preferenciji rizika i očekivanog povrata.



Grafikon 1. Prikaz položaja tržišnog indeksa u odnosu na efikasnu granicu portfelja⁵⁷

Prilikom ucrtavanja koordinati CROBEX-a na graf, odnosno vrijednosti očekivanog prinosa i standardne devijacije vrlo se lako uočava da isti ne pripada efikasnoj granici odabranih dionica. Isto tako, sukladno prikazanim podacima, također se može zaključiti da CROBEX ne predstavlja dobru zamjenu za tržišni portfelj, odnosno da nije efikasan.

⁵⁷ Izračun autora

4.4. Regresijska analiza


Tablica 5. Kovarijanca i beta indeks odabranog portfelja dionica

KOVARIJANCA	0,00082	0,00087	0,00189	0,00069	0,00044	0,00016	0,00099	0,00109	0,0009	0,0008
B	0,97629	1,03651	2,24295	0,81843	0,52712	0,19064	1,17496	1,2954	1,0523	0,8969

Tablica 6. Prikaz očekivanog prinosa i standardne devijacije

E(R)	0,01237	0,00946	-0,00264	-0,00598	0,00341	-0,00392	0,00819	-0,03954	-0,01356	0,00476
Σ	0,04758	0,04781	0,125731	0,041273	0,05138	0,055272	0,05981	0,137738	0,073585	0,06696

Unutar regresijske analize, provedene na temelju odabranog uzorka dionica prikazan je i dijagram rasipanja za odabrani uzorak (Grafikon 2).



Grafikon 2. Dijagram rasipanja

Dijagramom rasipanja prikazana je veza očekivanog prinosa dionica i beta vrijednosti dionice, pri čemu beta vrijednost dionice predstavlja nezavisnu varijablu, a očekivani prinos zavisnu varijablu. Iz prikazanog dijagrama rasipanja se može uočiti da ne postoji jasna povezanost između kretanja beta vrijednosti beta i očekivanog prinosa.

Povezanost varijabli testira se korelacijskom analizom, dok se utjecaj beta indeksa dionice na očekivan prinos testira linearnim regresijskim modelom.

Tablica 7. Korelacijska analiza

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate
1	,156 ^a	,024	-,098	,01590349

a. Predictors: (Constant), beta dionice

Vrijednost koeficijenta korelacije -0,156 ukazuje na ne postojanje povezanosti (empirijska p vrijednost 66,67%).

Reprezentativnost ocijenjenog modela utjecaja bete dionice na očekivan prinos dionice testirana je koeficijentom determinacije koji je u procijenjenom modelu jednak 0,024, što znači da je svega 2,4% odstupanja očekivanih vrijednosti prinosa od aritmetičke sredine protumačeno ocijenjenim regresijskim modelom. Model nije reprezentativan. Statistička značajnost modela u cjelini testirana je ANOVA testom.

Tablica 8. Rezultati regresijske analize

ANOVA^a

Model	Sum of Squares	df	Mean Square	F	Sig.
1 Regression	,000	1	,000	,200	,667 ^b
Residual	,002	8	,000		
Total	,002	9			

a. Dependent Variable: E(R)

b. Predictors: (Constant), beta dionice

Na temelju F vrijednosti 0,200 pri razini signifikantnosti od 66,7% donosi se zaključak da model kao cjelina nije statistički značajan. Dakle, svi ocijenjeni parametri linearnog modela su jednaki nuli.

5. ZAKLJUČAK

Još od vremena kada se u ljudskoj povijesti počelo govoriti o riziku, vrijednosnim papirima, prinosu te trgovanju istima misterij je bio povezanost između elemenata rizika i prinosa. Jedno od najbitnijih istraživanja tog područja započeo je H. Markowitz pedesetih godina prošlog stoljeća. Jednostavnost Markowitzevog modela i tumačenja dobivenih rezultata uzrokovala je činjenicu da je to najčešće korišten model u istraživanju tog područja. Markowitz je unutar svog modela postavio osnovne definicije pojmova kao što su rizik i prinos portfelja te očekivana vrijednost prinosa i varijanca prinosa. Također, jedan od doprinosa ovog modela je postavljanje i pojma efikasne granice, odnosno skupa portfelja koji maksimiziraju razinu prinosa za danu razinu neizvjesnosti (rizika). Međutim, kao glavni doprinos Markowitzevog modela modernoj teoriji portfelja navodi se upravo zaključak da portfelji sastavljeni od različitih vrijednosnih papira u konačnici mogu imati manju razinu rizika nego svaki vrijednosni papir pojedinačno.

Markowitzev model u budućnosti poslužio je kao temelj nastanka CAPM modela za procjenu kapitalne imovine. Uz pretpostavke da su svi investitori neskloni riziku, da na tržištu ne postoje troškovi kao što su porezi te da svi investitori dijele stavove o vjerojatnostima povrata na vrijednosne papire, ipak predstavlja idiličnu sliku tržišta, kakvog u suvremenom svijetu ne možemo pronaći. Upravo iz tog razloga gotovo sva istraživanja temeljena na ovom modelu vrlo lako se mogu proglasiti nevažećima, no postoje i područja u kojima se i četiri desetljeća nakon postavljanja isključivo koriste, a to je procjena troška kapitala tvrtke i procjena uspješnosti upravljanja portfeljima.

Hrvatsko tržište kapitala uspostavljeno je još 1907. godine, no zbog zbivanja u svjetskim gospodarstvima obnovljena je tek 1991. godine i odatle bilježi stope rasta sve do 2008. godine kada i hrvatsko gospodarstvo ulazi u ekonomsku krizu, nakon koje i ovo tržište pokazuje pozitivne stope rasta i oporavka koje ujedno predstavljaju i njegov daljnji napredak. Prikaz empirijskog istraživanja CAPM modela na hrvatskom tržištu kapitala započinje odabirom 10 dionica tržišta te prikazom njihovih zaključnih cijena po tjednima 2016. i 2017. godine.

Promjenjujući CAPM na Zagrebačkoj burzi, u radu su prikazani izračuni očekivanog prinosa portfelja dionica te beta koeficijenta kroz regresijsku i korelacijsku analizu stvarnog kretanja 10 redovnih dionica. Sukladno prikazanom dijagramu rasipanja te rezultatima provedenih analiza utvrđeno je da ne postoji jasna povezanost između beta indeksa i očekivanog prinosa dionica. Samim time, iz istraživanja proizlazi vrlo bitan zaključak, a to je da CAPM model nije validan na hrvatskom tržištu kapitala, čime se ujedno i prihvaća glavna hipoteza H1 postavljena u radu.

SAŽETAK

Temelj istraživanja ovog rada prvi je postavljeni model koji je na tržištu istražio vezu između rizika i prinosa vrijednosnica kojima se na istom tržištu i trguje. Nastavak na isti je CAPM model koji ujedno čini i predmet ovog istraživanja. Odnosno, fokus rada je stavljen na teoretski prikaz temeljnih postavki oba modela, njihovog razvoja i važnosti za modernu teoriju portfelja kritike i slabosti kod primjene oba modela u praksi, ali i primjenjivost novijeg modela na hrvatskom tržištu kapitala. Na odabranom uzorku dionica kojima se trguje na hrvatskom tržištu kapitala, točnije na Zagrebačkoj burzi regresijskom je i korelacijskom analizom utvrđena veza između kretanja vrijednosti dionica i primjenjivosti CAPM modela. Svi rezultati ostvareni su korištenjem nekoliko znanstvenih metoda: induktivnom metodom, deduktivnom metodom, komparativnom te metodom dokazivanja, te statističkom i matematičkim metodama.

Ključne riječi: Markowitzev model, CAPM, tržište kapitala, beta indeks, dionice

ABSTRACT

The basis of this paper is the first model to investigate the relationship between risk and return on securities traded on the financial market. Continuing to the CAPM model, which also makes the subject of this research. Indeed, the focus of the paper is placed on the theoretical view of the fundamental set of both models, their development and their relevance for the modern theory, of criticality and weaknesses in the application of both models in practice, as well as the applicability of a newer model on the Croatian capital market. On the selected sample of shares traded on the Croatian capital market, more precisely on the Zagreb Stock Exchange, using regression and correlation analysis author established the relationship between the movement of the value of shares and the applicability of the CAPM model. All results were obtained using several scientific methods: inductive method, deductive method, comparative and demonstration method, and statistical and mathematical methods.

Key words: Markowitz model, CAPM, capital market, beta index, stocks

POPIS SLIKA I TABLICA

Slika 1. Skup mogućih portfelja	13
Slika 2. Skup minimalne varijance (lijevo) i efikasna granica (desno)	14
Slika 3. Krivulja indiferencije	16
Slika 4. Linija tržišta kapitala - CML	23
Tablica 1. Uzorak dionica koje su izabrane za istraživanje	33
Tablica 2. Matrica varijanci i kovarijanci	36
Tablica 3. Prosječan tjedni prinos i standardna devijacija odabranih dionica	37
Tablica 4. Prikaz prinosa i standardne devijacije dionica	38
Tablica 5. Kovarijanca i beta indeks odabranog portfelja dionica	41
Tablica 6. Prikaz očekivanog prinosa i standardne devijacije	41
Tablica 7. Korelacijska analiza	43
Tablica 8. Rezultati regresijske analize	43
Grafikon 1. Prikaz položaja tržišnog indeksa u odnosu na efikasnu granicu portfelja	40
Grafikon 2. Dijagram rasipanja	42

LITERATURA

1. Aljinović, Z., Marasović, B., Šego, B., Financijsko modeliranje, Zgombić i Partneri, Zagreb 2008.
2. Aljinović, Z., Marasović, B., Šego, B., Financijsko modeliranje (II. izmijenjeno i dopunjeno izdanje), Ekonomski fakultet Split, 2011.
3. Bagarić, I., Testiranje CAPM modela - analiza na hrvatskom tržištu kapitala, Diplomski rad, Split, 2011., str. 19
4. Black, F., Jensen, M.C., Scholes, M., The Capital Asset Pricing Model: Some empirical tests, Praeger Publishers Inc., 1972., str. 1-54
5. Burton, J., Revisiting The Capital Asset Pricing Model, Dow Jones Asset Manager, 1998., str. 20-28
6. Belak, S., Uvod u znanost, Škola za turistički menadžment u Šibeniku, 2005.
7. Choudhary, K., Choudhary, S., Testing Capital Asset Pricing Model: Empirical Evidences from Indian Equity Market, Eurasian Journal of Business and Economics Vol. 3., No. 6., 2010., str. 127-138
8. Čerdić, I., Diverzifikacija kao osnova za kreiranje optimalnog portfelja, Škola biznisa Vol. 1., 2015., str. 138-152
9. Engle, R.F., Risk and volatility: econometric models and financial practice, Nobel Lecture, 2003., str. 313-335
10. Fama, E.F., French, K.R., The Capital Asset Pricing Model: Theory and Evidence, The Journal of Economic Perspectives, Vol. 18, No. 3, 2004., str. 25-46
11. Jarrow, R., et al., Portfolio Theory, Handbooks on OR&MS, 1995.
12. Janković, D., PRIMJENA CAPM U VREDNOVANJU IMOVINE NA CRNOGORSKOM TRŽIŠTU KAPITALA, Montenegrin Journal of Economics, Vol. 10., 2009., str. 81-94
13. Jerončić, M., Aljinović, Z., FORMIRANJE OPTIMALNOG PORTFELJA POMOĆU MARKOWITZEVOG MODELA UZ SEKTORSKU PODJELU KOMPANIJA, Ekonomski pregled Vol. 62., 2011., str. 583-606
14. Jakšić, S., Primjena Markowitzeve teorije na tržište dionica Zagrebačke burze, Zbornik Ekonomskog fakulteta u Zagrebu, godina 5, 2007., str. 331-334

15. Karačić, D., Bestvina Bukvić, I., Research of investment risk using beta coefficient, Interdisciplinary management Vol. X., 2014., str. 521-530
16. Litner, J., The valuation of risk assets and the selection of risky investments in stock portfolios nad capital budgets, The Review of economics and statistics Vol. 47. No. 1., 1965., str. 13-37
17. Latković, M., Upravljanje rizicima: identifikacija, mjerenje i kontrola, Financijska teorija i praksa Vol. 26, No. 2., str. 463-477
18. Laković, A., Optimizacija portfelja dionica na primjeru Zagrebačke burze, Diplomski rad, Rijeka, 2016., str. 17
19. Perold, A.F., The Capital Asset Pricing Model, Journal of Economic Perspectives vol. 18, No. 3., 2004., str. 3-24
20. Sharpe, W., Investor Wealth Measures and expected return, ICFA Continuing Education Series Vol. 1, 1990., str. 29
Ekonomskega fakulteta u Zagrebu, godina 5, 2007., str. 331-349
21. Škrinjarić, T., Šošćarić, N., Komplementarnost metodologije Markovljevih lanaca i Markowitzeva modela optimizacije portfelja, Ekonomska misao i praksa Vol. XXIII br.1., 2014., str. 354-357
22. Šupe, N., Prinosi i rizici dionica na tržištu kapitala Republike Hrvatske, Sveučilište u Splitu, Ekonomski fakultet, Split, 2016., str. 15
23. Tomić-Plazibat, N., Aljinović, Z., Marasović, B., Matematički modeli u financijskom upravljanju, Sveučilište u Splitu, Ekonomski fakultet, Split, 2006.
24. Učkar, D., Nikolić, J., SML model i hrvatsko tržište kapitala, Ekonomska istraživanja Vol. 21, No. 1., 2008., str. 1-10
25. Vidučić, Lj., Financijski menadžment, RRI plus, V. izdanje, Split, 2006.
26. van Horne, J., Financijsko upravljanje i politika, Deveto izdanje, Mate Zagreb, 1997.
27. Varian, H., A Portfolio of Nobel Laureates: Markowitz, Miller and Sharpe, Journal of Economic Perspective Vol. 7, No. 1., 1993., str. 159-160
28. Zagrebačka burza, www.zse.hr
29. Žiravac Mladenović, M., Najdanović, Z., Procjena beta koeficijenta za akcije koje kotiraju na banjalučkoj berzi, International Conference on Social and Technological Development (STED 2012). 2012., str. 1-12

Prilozi

Prilog 1. Pregled zaključnih cijena po tjednima za odabrane dionice

Pregled zaključnih cijena po tjednima za 10 dionica CROBEX-a											
Vrijeme	CROBEX	ADRS2	ATGR	ATPL	HT	KRAS	LKPC	PODR	PTKM	ULPL	ZABA
27.12.2015	1675,88	367	828,2	130	144	490	680	327,51	13	135	37
4.1.2016	1667,84	361	818	124,51	142	490	680	325,19	13	133	37,441
11.1.2016	1633,01	361,66	821,01	130	142	500	653	329,99	12,49	136	36,23
18.1.2016	1576,47	336,51	805,09	114,51	139	500	625	311	11,18	130	36
25.1.2016	1597,47	344	810,01	115,77	139	501,71	630	315,01	11,84	132	36,7
1.2.2016	1616,66	345,02	814,01	116,01	141	501	620,3	320,1	13	129	37,51
8.2.2016	1604,42	340,61	815	106,45	141	500	630	317	11,8	131	38,27
15.2.2016	1598,41	341,57	807,57	104	141	505	614	313	9,4	114	37,51
22.2.2016	1625,94	359,1	813	101,5	147	512	620,2	315,01	9,57	124	38,41
29.2.2016	1614,28	359,28	809	99,53	141	515	619,1	316,49	11	127	39,4
7.3.2016	1607,23	354	810	114,99	141	555	581	310	11,29	122,5	38,79
14.3.2016	1615,9	359,99	805,5	114,5	143	543	623	309	11,8	120	39,49
21.3.2016	1635,74	378,2	800,01	106	143	527	600	326,9	10,75	113	38,31
28.3.2016	1658,9	380	808,51	113,37	143	550	600,2	320,01	10,5	111	39,5
4.4.2016	1666,34	392	828,98	117	146	544	602,1	315,07	11	117,5	40,2
11.4.2016	1664,77	391	819,91	114,32	147	532	607	322	11,26	113,5	41
18.4.2016	1678,67	400	815	117,77	146	520,07	600,7	324	10,43	119	41
25.4.2016	1688,06	392,01	812,61	125	146	523	603,4	327	10,99	116	40,98
2.5.2016	1690,5	391,5	810,01	122,44	143	520	580	335,5	11,02	120	41,96
9.5.2016	1689,13	392	819,89	123,65	139	510	580,1	343	13	112,5	41
16.5.2016	1693,77	393	820	128	140	484	586	340	12,5	111,2	39,99
23.5.2016	1698,81	390	815,15	128,01	140	474	591	344,2	12,1	110,5	39,6
30.5.2016	1712,06	386	815	134	140	474	582	347	13,17	112	39,25
6.6.2016	1697,99	386,02	820	128,02	140	480	580	340	12,5	111	40,87
13.6.2016	1698,71	395,49	821,01	134,6	141	475,77	575,6	342,5	11,27	110	39,01
20.6.2016	1683,25	394	820	135	141	485	575,1	340	12	110	38,02
27.6.2016	1649,57	384	792,1	130,02	139	480	557,3	326	12	108	39,03
4.7.2016	1685,49	371	813,28	137	141	475,8	558	334,99	12,82	108	39,2
11.7.2016	1713,64	382	816	146,01	143	475,84	571	339,95	12,89	106,9	39,22
18.7.2016	1723,94	383,01	820,05	174	143	485,03	580	334	13,98	116,4	39,75
25.7.2016	1752,37	400	818	192	143	505,02	575,2	343,1	16,41	137	40,55
1.8.2016	1763,4	400	816,06	175,02	142	510	581	349,99	17	129	41,99
8.8.2016	1780,9	407	814,03	178,75	143	510	586	359,95	17,25	124	41,96
15.8.2016	1784,99	403,99	815,01	190,5	143	515	600	359,2	20,18	138,5	42,22
22.8.2016	1795,36	410	816,01	173,09	143	510	581,2	360,99	19,65	126	42,49

29.8.2016	1807,66	403,31	820,01	177,5	146	515	581,3	359,3	20,51	130	41,9
5.9.2016	1817,05	409,98	823	177	153	525	560,1	357	19,04	129	41,22
12.9.2016	1852,59	424,94	848	181,41	156	520	563,1	363	19	127	41,07
19.9.2016	1880,06	424,9	857	182,99	161	525	570	362,99	18,97	125	46,89
26.9.2016	1948,92	445	877,2	188,01	167	525	609,2	382	19,36	126	49,12
3.10.2016	1942,94	440	878,05	175,06	165	525	571,8	380	17,5	125	48,5
10.10.2016	1997,46	473,8	879,99	223,01	164	530	589	381,8	19,7	129	52
17.10.2016	1971,55	460	865,5	254	161	520,11	582	375	19,72	130	49,58
24.10.2016	1960,73	446,13	866,15	310,95	161	530	580,1	371,5	21,83	131	51
31.10.2016	1958,94	452	868	300	163	530	557	365,22	18,01	133,2	50
7.11.2016	1939,14	450	877,55	308,9	163	530	542	368,2	18,49	133	47,4
14.11.2016	1975,95	458,95	877,26	367,9	163	530	540	377	18,01	169	46,71
21.11.2016	1982,94	453,99	875	371,4	163	530	560	385	17,5	180	49
28.11.2016	1986,76	457,02	885	343,9	164	532,53	558	386	17,79	159	51
5.12.2016	1975,54	456,16	873	333	168	540	561	371,2	17,34	159	51
12.12.2016	1985,9	456	869,05	320	171	540	561,5	376,7	17,51	156	55
19.12.2016	1967,12	456,45	865	260	172	540	562	373,41	16,85	155	52
26.12.2016	1998,11	456,56	880	304,99	175	532,8	563	381,99	16,93	164	53,01
2.1.2017	1991,97	454,04	870	274,01	170	540	577,9	382,45	17,07	156,1	54
9.1.2017	2036,13	461,2	882,75	285	168	540	561	385	16,17	157	58
16.1.2017	2070,73	466	912	293,99	173	540	561,2	379,05	17,12	162,5	59
23.1.2017	2092,5	470	940	316	174	545	562	384,99	17,85	162	59,4
30.1.2017	2124,91	475	921	340,31	173	555	575	410	18,3	180	59
6.2.2017	2182,06	490	931,11	318	174	560	565,1	414	17,95	160,7	61,16
13.2.2017	2154,48	492,2	939	307,01	176	560	565,1	406,38	16,51	167	62
20.2.2017	2222,97	499,4	950	321,5	182	560	560,4	434	16,32	171,7	64,95
27.2.2017	2229,39	512	983	314,94	190	563,01	566	414,09	16,15	167	64,8
6.3.2017	2209,54	504	895,5	353,98	186	560	561	407	16,68	182	65,6
13.3.2017	2224,39	497,9	920	392	184	570	577,8	403,15	15,81	183,1	66,72
20.3.2017	2154,34	489,1	900	385	179	535	554	381,51	15,3	180	65,35
27.3.2017	2096,8	483	872,11	416	173	515	550	364,95	15	188	63,5

Prilog 2. Prikaz tjednog prinosa dionica

Pregled tjednog prinosa na 10 odabranih dionica CROBEX-a											
Vrijeme	CROBEX	ADRS2	ATGR	ATPL	HT	KRAS	LKPC	PODR	PTKM	ULPL	ZABA
4.1.2016	-0,48%	1,65%	1,24%	-4,31%	1,51%	0,00%	0,00%	0,71%	0,00%	-1,49%	1,18%
11.1.2016	-2,11%	0,18%	0,37%	4,31%	0,39%	2,02%	4,05%	1,47%	-4,00%	2,23%	-3,29%
18.1.2016	-3,52%	7,21%	1,96%	12,69%	2,13%	0,00%	4,38%	5,93%	11,08%	-4,51%	-0,64%
25.1.2016	1,32%	2,20%	0,61%	1,09%	0,29%	0,34%	0,80%	1,28%	5,74%	1,53%	1,93%
1.2.2016	1,19%	0,30%	0,49%	0,21%	1,82%	0,14%	1,55%	1,60%	9,35%	-2,30%	2,18%
8.2.2016	-0,76%	1,29%	0,12%	-8,60%	0,33%	0,20%	1,55%	0,97%	-9,68%	1,54%	2,01%
15.2.2016	-0,38%	0,28%	0,92%	-2,33%	0,13%	1,00%	2,57%	1,27%	22,74%	13,90%	-2,01%
22.2.2016	1,71%	5,00%	0,67%	-2,43%	4,04%	1,38%	1,00%	0,64%	1,79%	8,41%	2,37%
29.2.2016	-0,72%	0,05%	0,49%	-1,96%	4,15%	0,58%	0,17%	0,47%	13,93%	2,39%	2,54%
7.3.2016	-0,44%	1,48%	0,12%	14,44%	0,25%	7,48%	6,35%	2,07%	2,60%	-3,60%	-1,56%
14.3.2016	0,54%	1,68%	0,56%	-0,43%	1,38%	2,19%	6,98%	0,32%	4,42%	-2,06%	1,79%
21.3.2016	1,22%	4,93%	0,68%	-7,71%	0,35%	2,99%	3,76%	5,63%	-9,32%	-6,02%	-3,03%
28.3.2016	1,41%	0,47%	1,06%	6,72%	0,41%	4,27%	0,03%	2,13%	-2,35%	-1,79%	3,06%
4.4.2016	0,45%	3,11%	2,50%	3,15%	2,42%	1,10%	0,31%	1,56%	4,65%	5,65%	1,76%
11.4.2016	-0,09%	0,26%	1,10%	-2,32%	0,34%	2,23%	0,81%	2,18%	2,34%	-3,42%	1,97%
18.4.2016	0,83%	2,28%	0,60%	2,97%	0,34%	2,27%	1,04%	0,62%	-7,66%	4,73%	0,00%
25.4.2016	0,56%	2,02%	0,29%	5,96%	0,14%	0,56%	0,44%	0,92%	5,23%	-2,55%	-0,05%
2.5.2016	0,14%	0,13%	0,32%	-2,07%	2,22%	0,58%	3,95%	2,57%	0,27%	3,39%	2,36%
9.5.2016	-0,08%	0,13%	1,21%	0,98%	3,20%	1,94%	0,01%	2,21%	16,52%	-6,45%	-2,31%
16.5.2016	0,27%	0,25%	0,01%	3,46%	1,42%	5,23%	1,02%	0,88%	-3,92%	-1,15%	-2,49%
23.5.2016	0,30%	0,77%	0,59%	0,01%	0,34%	2,09%	0,85%	1,23%	-3,25%	-0,64%	-0,98%
30.5.2016	0,78%	1,03%	0,02%	4,57%	0,19%	0,00%	1,54%	0,81%	8,47%	1,36%	-0,89%
6.6.2016	-0,83%	0,01%	0,61%	-4,57%	0,32%	1,26%	0,34%	2,04%	-5,22%	-0,91%	4,04%

13.6.2016	0,04%	2,42%	0,12%	5,01%	0,74%	-	-	0,73%	10,36%	-0,90%	-4,66%
20.6.2016	-0,91%	0,38%	0,12%	0,30%	0,44%	1,92%	0,09%	0,73%	6,28%	0,00%	-2,57%
27.6.2016	-2,02%	2,57%	3,46%	-3,76%	1,16%	1,04%	3,14%	4,20%	0,00%	-1,84%	2,62%
4.7.2016	2,15%	3,44%	2,64%	5,23%	1,58%	0,88%	0,13%	2,72%	6,61%	0,00%	0,43%
11.7.2016	1,66%	2,92%	0,33%	6,37%	0,92%	0,01%	2,30%	1,47%	0,54%	-1,01%	0,05%
18.7.2016	0,60%	0,26%	0,50%	17,54%	0,35%	1,91%	1,56%	1,77%	8,12%	8,50%	1,34%
25.7.2016	1,64%	4,34%	0,25%	9,84%	0,33%	4,04%	0,83%	2,69%	16,03%	16,31%	1,99%
1.8.2016	0,63%	0,00%	0,24%	-9,26%	0,20%	0,98%	1,01%	1,99%	3,53%	-6,02%	3,49%
8.8.2016	0,99%	1,73%	0,25%	2,11%	0,19%	0,00%	0,86%	2,81%	1,46%	-3,91%	-0,07%
15.8.2016	0,23%	0,74%	0,12%	6,37%	0,13%	0,98%	2,36%	0,21%	15,69%	11,03%	0,62%
22.8.2016	0,58%	1,48%	0,12%	-9,58%	0,21%	0,98%	3,18%	0,50%	-2,66%	-9,46%	0,64%
29.8.2016	0,68%	1,65%	0,49%	2,52%	2,03%	0,98%	0,00%	0,47%	4,28%	3,13%	-1,40%
5.9.2016	0,52%	1,64%	0,36%	-0,28%	4,85%	1,92%	3,71%	0,64%	-7,44%	-0,77%	-1,64%
12.9.2016	1,94%	3,58%	2,99%	2,46%	2,00%	0,96%	0,54%	1,67%	-0,21%	-1,57%	-0,36%
19.9.2016	1,47%	0,01%	1,06%	0,87%	2,89%	0,96%	1,21%	0,00%	-0,16%	-1,58%	13,25%
26.9.2016	3,60%	4,62%	2,33%	2,71%	3,90%	0,00%	6,65%	5,10%	2,04%	0,80%	4,65%
3.10.2016	-0,31%	1,13%	0,10%	-7,14%	1,38%	0,00%	6,34%	0,52%	10,10%	-0,80%	-1,27%
10.10.2016	2,77%	7,40%	0,22%	24,21%	0,88%	0,95%	2,96%	0,47%	11,84%	3,15%	6,97%
17.10.2016	-1,31%	2,96%	1,66%	13,01%	1,58%	1,88%	1,20%	1,80%	0,10%	0,77%	-4,77%
24.10.2016	-0,55%	3,06%	0,08%	20,23%	0,31%	1,88%	0,34%	0,94%	10,17%	0,77%	2,82%
31.10.2016	-0,09%	1,31%	0,21%	-3,58%	1,55%	0,00%	4,05%	1,70%	19,24%	1,67%	-1,98%
7.11.2016	-1,02%	0,44%	1,09%	2,92%	0,15%	0,00%	2,73%	0,81%	2,63%	-0,15%	-5,34%
14.11.2016	1,88%	1,97%	0,03%	17,48%	0,20%	0,00%	0,38%	2,36%	-2,63%	23,95%	-1,47%
21.11.2016	0,35%	1,09%	0,26%	0,95%	0,26%	0,00%	3,64%	2,10%	-2,87%	6,31%	4,79%
28.11.2016	0,19%	0,67%	1,14%	-7,69%	0,61%	0,48%	0,36%	0,26%	1,64%	12,41%	4,00%
5.12.2016	-0,57%	0,19%	1,37%	-3,22%	2,72%	1,39%	0,53%	3,91%	-2,56%	0,00%	0,00%

		-	-								
12.12.2016	0,52%	0,04%	0,45%	-3,98%	1,76%	0,00%	0,09%	1,47%	0,98%	-1,89%	7,55%
			-	-				-			
19.12.2016	-0,95%	0,10%	0,47%	20,76%	0,65%	0,00%	0,09%	0,88%	-3,84%	-0,66%	-5,61%
						-					
26.12.2016	1,56%	0,02%	1,72%	15,96%	1,67%	1,34%	0,18%	2,27%	0,47%	5,64%	1,92%
		-	-	-	-						
2.1.2017	-0,31%	0,55%	1,14%	10,71%	2,90%	1,34%	2,61%	0,12%	0,82%	-4,94%	1,85%
					-		-				
9.1.2017	2,19%	1,56%	1,45%	3,93%	1,18%	0,00%	2,97%	0,66%	-5,42%	0,58%	7,15%
								-			
16.1.2017	1,69%	1,04%	3,26%	3,11%	2,93%	0,00%	0,04%	1,56%	5,71%	3,44%	1,71%
23.1.2017	1,05%	0,85%	3,02%	7,22%	0,58%	0,92%	0,14%	1,55%	4,18%	-0,31%	0,68%
			-	-							
30.1.2017	1,54%	1,06%	2,04%	7,41%	0,80%	1,82%	2,29%	6,29%	2,49%	10,54%	-0,68%
							-			-	
6.2.2017	2,65%	3,11%	1,09%	-6,78%	0,51%	0,90%	1,74%	0,97%	-1,93%	11,34%	3,60%
							-	-			
13.2.2017	-1,27%	0,45%	0,84%	-3,52%	1,37%	0,00%	0,01%	1,86%	-8,36%	3,84%	1,36%
							-				
20.2.2017	3,13%	1,45%	1,16%	4,61%	3,41%	0,00%	0,83%	6,58%	-1,16%	2,80%	4,65%
								-			
27.2.2017	0,29%	2,49%	3,41%	-2,06%	4,04%	0,54%	0,99%	4,70%	-1,05%	-2,79%	-0,23%
		-	-		-	-	-	-			
6.3.2017	-0,89%	1,57%	9,32%	11,69%	2,10%	0,54%	0,89%	1,73%	3,23%	8,60%	1,23%
		-			-			-			
13.3.2017	0,67%	1,22%	2,70%	10,20%	0,67%	1,77%	2,95%	0,95%	-5,36%	0,58%	1,69%
		-	-		-	-	-	-			
20.3.2017	-3,20%	1,78%	2,20%	-1,80%	3,14%	6,34%	4,20%	5,52%	-3,28%	-1,68%	-2,07%
		-	-		-	-	-	-			
27.3.2017	-2,71%	1,26%	3,15%	7,74%	3,48%	3,81%	0,73%	4,44%	-1,98%	4,35%	-2,87%

Prilog 3. Matrica A

MATRICA A										
Vrijeme	ADRS2	ATGR	ATPL	HT	KRAS	LKPC	PODR	PTKM	ULPL	ZABA
4.1.2016	-	-	-	-	-	-	-	-	-	-
	2,07%	1,32%	-6,10%	1,79%	0,08%	0,33%	0,88%	-0,22%	-2,00%	0,35%
11.1.2016	-	-	-	-	-	-	-	-	-	-
	0,24%	0,29%	2,53%	0,12%	1,94%	3,73%	1,30%	-4,22%	1,72%	-4,12%
18.1.2016	-	-	-	-	-	-	-	-	-	-
	7,63%	2,04%	14,48%	2,41%	0,08%	4,06%	6,09%	11,30%	-5,02%	-1,47%
25.1.2016	-	-	-	-	-	-	-	-	-	-
	1,78%	0,53%	-0,70%	0,57%	0,26%	1,12%	1,11%	5,52%	1,02%	1,09%
1.2.2016	-	-	-	-	-	-	-	-	-	-
	0,13%	0,41%	-1,58%	1,54%	0,22%	1,23%	1,44%	9,13%	-2,81%	1,35%
8.2.2016	-	-	-	-	-	-	-	-	-	-
	1,71%	0,04%	10,39%	0,61%	0,28%	1,88%	1,14%	-9,91%	1,03%	1,17%
15.2.2016	-	-	-	-	-	-	-	-	-	-
	0,14%	1,00%	-4,12%	0,15%	0,92%	2,25%	1,44%	22,96%	14,41%	-2,84%
22.2.2016	-	-	-	-	-	-	-	-	-	-
	4,58%	0,59%	-4,22%	3,76%	1,30%	1,33%	0,47%	1,57%	7,90%	1,54%
29.2.2016	-	-	-	-	-	-	-	-	-	-
	0,37%	0,57%	-3,75%	4,43%	0,51%	0,15%	0,30%	13,71%	1,88%	1,71%
7.3.2016	-	-	-	-	-	-	-	-	-	-
	1,90%	0,04%	12,65%	0,53%	7,40%	6,02%	2,24%	2,38%	-4,11%	-2,39%
14.3.2016	-	-	-	-	-	-	-	-	-	-
	1,26%	0,64%	-2,22%	1,10%	2,26%	7,31%	0,49%	4,20%	-2,57%	0,96%
21.3.2016	-	-	-	-	-	-	-	-	-	-
	4,51%	0,76%	-9,50%	0,07%	3,07%	3,43%	5,46%	-9,54%	-6,53%	-3,86%
28.3.2016	-	-	-	-	-	-	-	-	-	-
	0,05%	0,98%	4,93%	0,69%	4,20%	0,36%	2,30%	-2,57%	-2,30%	2,23%
4.4.2016	-	-	-	-	-	-	-	-	-	-
	2,69%	2,42%	1,36%	2,14%	1,17%	0,64%	1,72%	4,43%	5,14%	0,93%
11.4.2016	-	-	-	-	-	-	-	-	-	-
	0,68%	1,18%	-4,11%	0,06%	2,31%	1,14%	2,01%	2,12%	-3,93%	1,14%
18.4.2016	-	-	-	-	-	-	-	-	-	-
	1,85%	0,68%	1,18%	0,62%	2,34%	0,71%	0,45%	-7,88%	4,22%	-0,83%
25.4.2016	-	-	-	-	-	-	-	-	-	-
	2,44%	0,37%	4,17%	0,14%	0,49%	0,77%	0,76%	5,01%	-3,06%	-0,88%
2.5.2016	-	-	-	-	-	-	-	-	-	-
	0,55%	0,40%	-3,86%	2,50%	0,65%	3,62%	2,40%	0,05%	2,88%	1,53%
9.5.2016	-	-	-	-	-	-	-	-	-	-
	0,29%	1,13%	-0,81%	3,48%	2,02%	0,33%	2,04%	16,30%	-6,96%	-3,15%
16.5.2016	-	-	-	-	-	-	-	-	-	-
	0,17%	0,07%	1,67%	1,14%	5,31%	1,35%	1,05%	-4,14%	-1,66%	-3,33%
23.5.2016	-	-	-	-	-	-	-	-	-	-
	1,19%	0,67%	-1,78%	0,61%	2,16%	1,18%	1,06%	-3,47%	-1,15%	-1,81%
30.5.2016	-	-	-	-	-	-	-	-	-	-
	1,45%	0,10%	2,78%	0,46%	0,08%	1,21%	0,64%	8,25%	0,85%	-1,72%
6.6.2016	-	0,53%	-6,35%	0,04%	1,18%	-	-	-5,44%	-1,42%	3,21%

	0,42%					0,02%	2,20%			
					-	-		-		
13.6.2016	2,00%	0,04%	3,22%	0,46%	0,96%	0,43%	0,57%	10,58%	-1,41%	-5,49%
	-	-		-			-			
20.6.2016	0,80%	0,20%	-1,49%	0,72%	1,84%	0,23%	0,90%	6,06%	-0,51%	-3,40%
	-	-		-	-	-	-			
27.6.2016	2,99%	3,54%	-5,55%	1,44%	1,11%	2,81%	4,37%	-0,22%	-2,35%	1,79%
	-			-	-					
4.7.2016	3,87%	2,56%	3,44%	1,30%	0,96%	0,46%	2,55%	6,39%	-0,51%	-0,40%
					-					
11.7.2016	2,50%	0,25%	4,58%	0,64%	0,07%	2,63%	1,30%	0,32%	-1,52%	-0,78%
	-						-			
18.7.2016	0,16%	0,42%	15,75%	0,07%	1,84%	1,89%	1,93%	7,90%	7,99%	0,51%
		-		-		-				
25.7.2016	3,92%	0,33%	8,05%	0,61%	3,96%	0,51%	2,52%	15,81%	15,80%	1,16%
	-	-	-	-						
1.8.2016	0,42%	0,32%	11,05%	0,48%	0,90%	1,33%	1,82%	3,31%	-6,53%	2,66%
		-		-	-					
8.8.2016	1,31%	0,33%	0,32%	0,09%	0,08%	1,19%	2,64%	1,24%	-4,42%	-0,90%
	-			-			-			
15.8.2016	1,16%	0,04%	4,58%	0,15%	0,90%	2,69%	0,38%	15,47%	10,52%	-0,21%
			-	-	-	-				
22.8.2016	1,05%	0,04%	11,37%	0,07%	1,05%	2,85%	0,33%	-2,88%	-9,97%	-0,19%
	-						-			
29.8.2016	2,07%	0,41%	0,73%	1,76%	0,90%	0,33%	0,64%	4,06%	2,62%	-2,23%
						-	-			
5.9.2016	1,22%	0,28%	-2,07%	4,58%	1,85%	3,38%	0,81%	-7,66%	-1,28%	-2,47%
					-					
12.9.2016	3,16%	2,91%	0,67%	1,72%	1,03%	0,87%	1,50%	-0,43%	-2,08%	-1,20%
	-						-			
19.9.2016	0,43%	0,98%	-0,92%	2,62%	0,88%	1,54%	0,17%	-0,38%	-2,09%	12,42%
					-					
26.9.2016	4,20%	2,25%	0,92%	3,62%	0,08%	6,98%	4,94%	1,81%	0,29%	3,82%
	-			-	-	-	-	-		
3.10.2016	1,55%	0,02%	-8,93%	1,66%	0,08%	6,01%	0,69%	10,32%	-1,31%	-2,10%
				-						
10.10.2016	6,98%	0,14%	22,42%	1,16%	0,87%	3,29%	0,31%	11,62%	2,64%	6,14%
	-	-		-	-	-	-			
17.10.2016	3,38%	1,74%	11,22%	1,86%	1,96%	0,87%	1,96%	-0,12%	0,26%	-5,60%
	-			-		-	-			
24.10.2016	3,48%	0,00%	18,44%	0,59%	1,81%	0,01%	1,10%	9,95%	0,26%	1,99%
					-	-	-	-		
31.10.2016	0,88%	0,13%	-5,37%	1,27%	0,08%	3,73%	1,87%	19,46%	1,16%	-2,81%
	-			-	-	-	-			
7.11.2016	0,87%	1,01%	1,13%	0,13%	0,08%	2,40%	0,65%	2,41%	-0,66%	-6,17%
		-		-	-	-				
14.11.2016	1,55%	0,11%	15,69%	0,48%	0,08%	0,05%	2,20%	-2,85%	23,45%	-2,30%
	-	-		-	-					
21.11.2016	1,51%	0,34%	-0,84%	0,54%	0,08%	3,96%	1,93%	-3,09%	5,80%	3,96%
						-			-	
28.11.2016	0,24%	1,06%	-9,48%	0,33%	0,40%	0,03%	0,09%	1,42%	12,91%	3,17%

	-	-					-			
5.12.2016	0,61%	1,44%	-5,01%	2,44%	1,32%	0,86%	4,08%	-2,78%	-0,51%	-0,83%
	-	-			-					
12.12.2016	0,46%	0,53%	-5,77%	1,49%	0,08%	0,42%	1,30%	0,76%	-2,40%	6,72%
	-	-	-		-					
19.12.2016	0,32%	0,55%	22,55%	0,37%	0,08%	0,41%	1,04%	-4,06%	-1,17%	-6,44%
	-				-					
26.12.2016	0,40%	1,64%	14,17%	1,39%	1,42%	0,50%	2,11%	0,25%	5,13%	1,09%
	-	-	-	-						
2.1.2017	0,98%	1,22%	12,50%	3,18%	1,27%	2,94%	0,05%	0,60%	-5,45%	1,02%
				-	-	-				
9.1.2017	1,14%	1,38%	2,14%	1,46%	0,08%	2,64%	0,50%	-5,64%	0,07%	6,31%
					-					
16.1.2017	0,61%	3,18%	1,32%	2,65%	0,08%	0,36%	1,72%	5,49%	2,93%	0,88%
23.1.2017	0,43%	2,94%	5,43%	0,30%	0,85%	0,47%	1,39%	3,96%	-0,82%	-0,16%
		-		-						
30.1.2017	0,64%	2,12%	5,62%	1,08%	1,74%	2,61%	6,13%	2,27%	10,03%	-1,51%
						-			-	
6.2.2017	2,69%	1,01%	-8,57%	0,23%	0,82%	1,41%	0,80%	-2,15%	11,85%	2,76%
					-					
13.2.2017	0,03%	0,76%	-5,31%	1,09%	0,08%	0,32%	2,02%	-8,58%	3,33%	0,53%
					-	-				
20.2.2017	1,03%	1,09%	2,82%	3,13%	0,08%	0,50%	6,41%	-1,38%	2,29%	3,82%
							-			
27.2.2017	2,07%	3,34%	-3,85%	3,76%	0,46%	1,32%	4,86%	-1,27%	-3,30%	-1,06%
	-	-		-	-	-				
6.3.2017	2,00%	9,40%	9,90%	2,38%	0,61%	0,56%	1,89%	3,01%	8,09%	0,40%
	-			-						
13.3.2017	1,64%	2,62%	8,41%	0,95%	1,69%	3,27%	1,12%	-5,58%	0,07%	0,86%
	-	-		-	-	-				
20.3.2017	2,21%	2,28%	-3,59%	3,42%	6,41%	3,87%	5,68%	-3,50%	-2,19%	-2,91%
	-	-		-	-	-				
27.3.2017	1,68%	3,23%	5,95%	3,76%	3,89%	0,40%	4,60%	-2,20%	3,84%	-3,70%

Prilog 4. Mjesečne cijene zatvaranja dionica

Vrijeme	mjesečne cijene zatvaranja dionica										
	ADRS	ATGR	ATPL	HT	KRAS	LKPC	PODR	PTKM	ULPL	ZABA	CROBEX
pro.11	218,99	500	331	242	440	717,98	231	194,99	361	40,58	1740,21
sij.12	213	475	307,95	238,58	443	649,5	247,5	194	312,56	39,8	1727,28
vlj.12	216,75	504,9	340	224,01	455,99	679	256,7	201,5	334,02	42	1787,23
ožu.12	211	500	370	214,4	421,12	717	249,99	275	330	45,48	1833,54
tra.12	217,9	518,95	320,01	207,01	410	700	236	268	324,93	42,43	1800,76
svi.12	212,01	490,01	280	198	400	702,06	219,04	241	273,2	37	1668,46
lip.12	220	492,99	274,89	205	385	699	229,99	247,85	270	38,01	1693,85
srp.12	215,1	462,5	274,95	205,05	400	654	210	247,5	269	39,21	1698,23
kol.12	216,99	463,5	250	200	400	631	215,5	224	252	38,79	1679,95
ruj.12	223	472,5	234,88	203	400	590	247,76	224,45	223,64	38,4	1715,24
lis.12	249,99	521,05	229	204,32	380	590	260	215	216,93	37,99	1754,82
stu.12	248,5	527,13	231	202,17	370,5	614	269,72	216,99	218,99	38	1760,16
pro.12	248,01	536	203,7	197,2	360	605	240,02	218,49	205	37,59	1740,39
sij.13	286,11	670	237	216,05	360,1	570	265,13	236,71	198,98	36,94	1887,81
vlj.13	290	681	259,5	216	440,01	522	270	227,99	191,92	38,9	1945,38
ožu.13	294,02	674	352,1	216,05	444,01	541	285	230,11	203,8	38	2007,94
tra.13	296	650	327	214,07	430	486	270,03	239,9	199	37	1948,39
svi.13	290,18	629	311,99	211,51	405	512,5	236	215	182	34,21	1853,97
lip.13	282	571	321	178,35	400,04	493,15	235	197,89	182,99	31,7	1804,69
srp.13	282,1	636	304,52	175	402,69	530	241,13	221,49	182,89	29	1848,55
kol.13	276	684,98	307,61	183,48	400,41	500	255	196,99	182,5	28,33	1841,41
ruj.13	267	650	362,63	174,2	400	463,98	250	206	179,23	26	1810,54
lis.13	265	659,02	352,78	167	390	444,99	244,8	179,6	181,97	26,91	1764,41
stu.13	271,98	698,99	367,95	171,61	400	442,3	246	173,69	188,8	26,4	1772,11
pro.13	277,01	718	394	176,65	410	442	254,55	167,99	197,39	29	1794,28
sij.14	274,01	743,01	383,03	169,89	372	540	276	144,5	202	26,65	1803,53
vlj.14	263,61	767	393,01	169,75	375	518	285,81	114	189,9	26,3	1795,09
ožu.14	263	765,03	385,13	165	367	520	285,42	68,06	193	28,45	1758,44
tra.14	266	808,44	333,01	155,56	352,82	499	282	60	181,97	27,64	1721,39
svi.14	275	834,5	330,16	155,5	313	498,97	292,9	44	171	30,7	1701,51
lip.14	277	881	332,87	151,84	320	515,05	304,54	41,9	173	34,55	1791,48
srp.14	293,01	928,19	334	149,7	355,02	540,01	301,02	36,2	177,5	32,5	1815,3
kol.14	300,51	981,01	367,29	151,85	340	539,98	317	33,94	183,99	37,65	1850,73
ruj.14	336,4	1030	385,2	162,83	360	579,88	340,1	30,09	180	37,4	1918,06
lis.14	340	993,25	365,1	158,5	341,33	687,97	307	26,21	173,01	35,39	1838,75
stu.14	332,03	943	341	154,5	365	696,99	291,5	29	166,9	35,81	1792,02
pro.14	340	940	308,5	150,5	367	667,97	293,47	27,5	154	33,5	1745,44
sij.15	343,9	926	315	159,2	390	670	292,02	27,05	152,5	34,4	1764,45
vlj.15	351	916,06	260	163	400	699,01	306,5	19	140	34	1745,56
ožu.15	330,9	900	239	162,01	400	715,99	290	18,88	150	37,99	1712,82

tra.15	333	920	216,12	164,3	415	698	320,99	17,6	158,79	35,6	1751,67
svi.15	364,99	897,02	203,9	154	415	700	310	17,35	147,9	36	1729,44
lip.15	370	889,98	202	154,32	455	703	310	15,9	143	42,35	1737,55
srp.15	404	893	216	156,5	458,11	700	319	16,97	167,78	42,2	1798,44
kol.15	401,5	850	202,15	149,03	437,01	700,01	322	15,8	150,9	39,2	1738,18
ruj.15	343,1	840	185,5	141,21	460,11	712,58	326	16,1	144	36,97	1685,63
lis.15	371,99	863	168,5	146,14	469	721,6	353	15,9	130,4	34	1725,1
stu.15	370,93	837,66	136,4	142,21	461,45	714,15	332,69	15,1	133	36,6	1680,19
pro.15	365	832,9	146	144,4	495	700	334,01	13,2	141,99	36,98	1689,63
sij.16	345	814,01	117,79	139,6	500	620,15	319	13,22	132	37,2	1612,19
vlj.16	359,28	809	99,53	141	515	619,09	316,49	11	123,5	39,4	1614,28
ožu.16	390,04	815	114	145	550	625	320,5	10,5	112	40,06	1669,68
tra.16	395	815	127,7	144,4	518	582	329	10,56	114	41,96	1688,48
svi.16	381,15	815,98	130,06	140,16	474	580	347	12,55	115	39,25	1704,64
lip.16	377,01	811,6	134,71	141,52	476	557,53	328,23	12,4	108	39	1675,95
srp.16	411,88	814	182	143,99	510,01	580	359	17	132,8	41,99	1773,97
kol.16	406	822	175	147	515	581	362,95	22,11	129,99	41	1818,39
ruj.16	437,5	869,5	180,02	163,98	525	582,2	379	17,99	124,1	49,5	1941,32
lis.16	452	868	300	163	530	557,01	365,22	18,01	133,2	50	1958,94
stu.16	462,3	885,2	335	165,3	536	560	387	18,26	169,99	52,39	1997,81
pro.16	459,9	882	282,55	169	540	567,5	377,5	18,18	160	54	1994,84

Prilog 5. Prinosi dionica

Vrijeme	Prinosi dionica									
	ADRS	ATGR	ATPL	HT	KRAS	LKPC	PODR	PTKM	ULPL	ZABA
pro.11										
sij.12	-0,0277	-0,0513	-0,0722	-0,0142	0,0068	0,1002	0,1725	-0,0051	-0,1441	-0,0194
vlj.12	0,0175	0,0533	0,0990	-0,0630	0,0289	0,0444	0,0670	0,0379	0,0664	0,0538
ožu.12	-0,0269	-0,0020	0,0846	-0,0438	-0,0796	0,0545	0,0265	0,3110	-0,0121	0,0796
tra.12	0,0322	0,0372	-0,1452	-0,0351	-0,0268	0,0240	0,0576	-0,0258	-0,0155	-0,0694
svi.12	-0,0274	-0,0574	-0,1336	-0,0445	-0,0247	0,0029	0,0746	-0,1062	-0,1734	-0,1369
lip.12	0,0370	0,0061	-0,0184	0,0347	-0,0382	0,0044	0,0488	0,0199	-0,0118	0,0269
srp.12	-0,0225	-0,0638	0,0022	0,0002	0,0382	0,0665	0,0909	0,0067	-0,0037	0,0311
kol.12	0,0087	0,0022	-0,0971	-0,0249	0,0000	0,0358	0,0259	-0,0998	-0,0653	-0,0108
ruj.12	0,0273	0,0192	-0,0624	0,0149	0,0000	0,0672	0,1395	0,0020	-0,1194	-0,0101
lis.12	0,1142	0,0978	-0,0254	0,0065	-0,0513	0,0000	0,0482	-0,0430	-0,0305	-0,0107
stu.12	-0,0060	0,0116	0,0087	-0,0106	-0,0253	0,0399	0,0367	0,0092	0,0095	0,0003
pro.12	-0,0020	0,0167	-0,1258	-0,0249	-0,0287	0,0148	0,1167	0,0069	-0,0660	-0,0108
sij.13	0,1429	0,2231	0,1514	0,0913	0,0003	0,0596	0,0995	0,0801	-0,0298	-0,0174
vlj.13	0,0135	0,0163	0,0907	-0,0002	0,2004	0,0880	0,0182	-0,0375	-0,0361	0,0517
ožu.13	0,0138	-0,0103	0,3052	0,0002	0,0090	0,0358	0,0541	0,0093	0,0601	-0,0234
tra.13	0,0067	-0,0363	-0,0740	-0,0092	-0,0321	0,1072	0,0540	0,0417	-0,0238	-0,0267
svi.13	-0,0199	-0,0328	-0,0470	-0,0120	-0,0599	0,0531	0,1347	-0,1096	-0,0954	-0,0784
lip.13	-0,0286	-0,0967	0,0285	-0,1705	-0,0123	0,0385	0,0042	-0,0829	0,0115	-0,0762
srp.13	0,0004	0,1078	-0,0527	-0,0190	0,0066	0,0721	0,0258	0,1127	0,0000	-0,0890
kol.13	-0,0219	0,0742	0,0101	0,0473	-0,0057	0,0583	0,0559	-0,1172	-0,0027	-0,0234
ruj.13	-0,0332	-0,0524	0,1646	-0,0519	-0,0010	0,0748	0,0198	0,0447	-0,0181	-0,0858
lis.13	-0,0075	0,0138	-0,0275	-0,0422	-0,0253	0,0418	0,0210	-0,1371	0,0152	0,0344
stu.13	0,0260	0,0589	0,0421	0,0272	0,0253	0,0061	0,0049	-0,0335	0,0368	-0,0191
pro.13	0,0183	0,0268	0,0684	0,0289	0,0247	0,0007	0,0342	-0,0334	0,0445	0,0939

sij.14	-0,0109	0,0342	-0,0282	-0,0390	-0,0973	0,2003	0,0809	-0,1506	0,0270	-0,0845
vlj.14	-0,0387	0,0318	0,0257	-0,0008	0,0080	0,0416	0,0349	-0,2371	-0,0657	-0,0132
ožu.14	-0,0023	-0,0026	-0,0203	-0,0284	-0,0216	0,0039	0,0014	-0,5158	0,0162	0,0786
tra.14	0,0113	0,0552	-0,1514	-0,0589	-0,0394	0,0412	0,0121	-0,1260	-0,0588	-0,0289
svi.14	0,0333	0,0317	-0,0026	-0,0004	-0,1198	0,0001	0,0379	-0,3102	-0,0622	0,1050
lip.14	0,0072	0,0542	0,0082	-0,0238	0,0221	0,0317	0,0390	-0,0489	0,0116	0,1181
srp.14	0,0562	0,0522	0,0034	-0,0142	0,1039	0,0473	0,0116	-0,1462	0,0257	-0,0612
kol.14	0,0253	0,0553	0,0950	0,0143	-0,0432	0,0001	0,0517	-0,0645	0,0359	0,1471
ruj.14	0,1128	0,0487	0,0476	0,0698	0,0572	0,0713	0,0703	-0,1204	-0,0219	-0,0067
lis.14	0,0106	-0,0363	-0,0536	-0,0270	-0,0533	0,1709	0,1024	0,1851	-0,0396	-0,0552
stu.14	-0,0237	-0,0519	-0,0683	-0,0256	0,0670	0,0130	0,0518	-0,2220	-0,0360	0,0118
pro.14	0,0237	-0,0032	-0,1002	-0,0262	0,0055	0,0425	0,0067	-0,0531	-0,0804	-0,0667
sij.15	0,0143	-0,0150	0,0209	0,0562	0,0608	0,0030	0,0050	-0,0165	-0,0098	0,0265
vlj.15	0,0175	-0,0108	-0,1919	0,0236	0,0253	0,0424	0,0484	-0,3532	-0,0855	-0,0117
ožu.15	-0,0590	-0,0177	-0,0842	-0,0061	0,0000	0,0240	0,0553	-0,0063	0,0690	0,1110
tra.15	0,0063	0,0220	-0,1006	0,0140	0,0368	0,0254	0,1015	-0,0702	0,0569	-0,0650
svi.15	0,0917	-0,0253	-0,0436	-0,0647	0,0000	0,0029	0,0348	-0,0143	-0,0710	0,0112
lip.15	0,0136	-0,0079	-0,0240	0,0021	0,0920	0,0043	0,0000	-0,0873	-0,0337	0,1624
srp.15	0,0879	0,0034	0,0670	0,0140	0,0068	0,0043	0,0286	0,0651	0,1598	-0,0035
kol.15	-0,0062	-0,0494	-0,0663	-0,0489	-0,0472	0,0000	0,0094	-0,0714	-0,1060	-0,0737
ruj.15	-0,1572	-0,0118	-0,0860	-0,0539	0,0515	0,0178	0,0123	0,0188	-0,0468	-0,0586
lis.15	0,0808	0,0270	-0,0961	0,0343	0,0191	0,0126	0,0796	-0,0125	-0,0992	-0,0837
stu.15	-0,0029	-0,0298	-0,2113	-0,0273	-0,0162	0,0104	0,0762	-0,0516	0,0197	0,0737
pro.15	-0,0161	-0,0057	0,0680	0,0153	0,0702	0,0200	0,0209	-0,1345	0,0654	0,0103
sij.16	-0,0564	-0,0229	-0,2147	-0,0338	0,0101	0,1211	0,0460	0,0015	-0,0730	0,0059
vlj.16	0,0406	-0,0062	-0,1684	0,0100	0,0296	0,0017	0,0079	-0,1838	-0,0666	0,0575
ožu.16	0,0821	0,0074	0,1357	0,0280	0,0658	0,0095	0,0126	-0,0465	-0,0977	0,0166
tra.16	0,0126	0,0000	0,1135	-0,0041	-0,0599	0,0713	0,0262	0,0057	0,0177	0,0463
svi.16	-0,0357	0,0012	0,0183	-0,0298	-0,0888	0,0034	0,0533	0,1726	0,0087	-0,0668
lip.16	-0,0109	-0,0054	0,0351	0,0097	0,0042	-	-	-0,0120	-0,0628	-0,0064

						0,0395	0,0556			
srp.16	0,0885	0,0030	0,3009	0,0173	0,0690	0,0395	0,0896	0,3155	0,2067	0,0739
kol.16	-0,0144	0,0098	-0,0392	0,0207	0,0097	0,0017	0,0109	0,2628	-0,0214	-0,0239
ruj.16	0,0747	0,0562	0,0283	0,1093	0,0192	0,0021	0,0433	-0,2062	-0,0464	0,1884
						-	-			
lis.16	0,0326	-0,0017	0,5107	-0,0060	0,0095	0,0442	0,0370	0,0011	0,0708	0,0101
stu.16	0,0225	0,0196	0,1103	0,0140	0,0113	0,0054	0,0579	0,0138	0,2439	0,0467
							-			
pro.16	-0,0052	-0,0036	-0,1703	0,0221	0,0074	0,0133	0,0249	-0,0044	-0,0606	0,0303